



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA

NATALIA PIMENTEL LADO CES

**OTIMIZAÇÃO ECONÔMICA DO SISTEMA DE GERENCIAMENTO DISTRIBUÍDO
DE ENERGIA DE MICRORREDES CA**

FORTALEZA

2023

NATALIA PIMENTEL LADO CES

OTIMIZAÇÃO ECONÔMICA DO SISTEMA DE GERENCIAMENTO DISTRIBUÍDO DE
ENERGIA DE MICRORREDES CA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica

Orientadora: Profa. Ph.D. Ruth Pastôra Saraiva Leão

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- C38o Ces, Natalia Pimentel Lado.
Otimização econômica do sistema de gerenciamento distribuído de energia de microrredes ca / Natalia Pimentel Lado Ces. – 2023.
102 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2023.
Orientação: Prof. Me. Ruth Pastôra Saraiva Leão.
1. Microrredes. 2. Otimização. 3. Despacho Econômico. 4. Consenso. 5. Difusão. I. Título.
CDD 621.3
-

NATALIA PIMENTEL LADO CES

OTIMIZAÇÃO ECONÔMICA DO SISTEMA DE GERENCIAMENTO DISTRIBUÍDO DE
ENERGIA DE MICRORREDES CA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica

Aprovada em: 20 de janeiro de 2023

BANCA EXAMINADORA

Profa. Ph.D. Ruth Pastôra Saraiva
Leão (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Raimundo Furtado Sampaio
Universidade Federal do Ceará (UFC)

Prof. Dr. Lucas Silveira Melo
Universidade Federal do Ceará (UFC)

Profa. Dra. Marina Lavorato de Oliveira
Pontifícia Universidade Católica de Campinas (PUC)

A Deus,

Aos meus pais, Andrea e Paulo

AGRADECIMENTOS

A Deus, que me presenteou com uma família maravilhosa, oportunidades enriquecedoras e várias pessoas que tanto me apoiaram e contribuíram muito com o meu crescimento.

Aos meus pais, Andrea e Paulo, que sempre estiveram presentes em todas as etapas da minha vida como minhas referências, contribuindo com o meu crescimento intelectual e humano.

A minha irmã Andressa, grande incentivadora e amiga de todas as etapas da minha vida.

A minha família, pela presença, união e cuidado que temos uns com os outros.

Ao meu namorado Lucas, que sempre foi apoio e companhia durante a graduação e mestrado, sempre me incentivando a buscar o meu melhor e me estimulando em momentos difíceis.

Aos meus professores do Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal do Ceará, em especial, a professora Ruth Leão pelo apoio, disponibilidade e valiosos ensinamentos que me proporcionaram um grande crescimento.

Aos colegas do Grupo de Redes Elétricas Inteligentes pelas trocas de conhecimento, enriquecedoras discussões e apoio durante o Mestrado.

Aos membros da banca avaliadora desse trabalho, professores Raimundo Furtado, Lucas Silveira e Marina Lavorato pelas contribuições para o aprimoramento do trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro durante o mestrado.

“Há uma força motriz mais poderosa que o vapor,
a eletricidade e a energia atômica: a vontade.”

(Albert Einstein)

RESUMO

As redes elétricas estão passando por um período de transição significativa na geração e uso de energia elétrica, o que implica na necessidade de mudanças normativas e tecnológicas. Dentre os aspectos que marcam essa transformação, verifica-se a difusão de recursos energéticos distribuídos, a maior necessidade de tecnologias de comunicação e o papel mais ativo do consumidor. Nesse contexto, destacam-se as microrredes, que agregam as mais recentes tecnologias de rede, marcando os novos modelos de sistemas de distribuição de energia elétrica. A natureza distribuída e variada dos recursos energéticos de uma microrrede demanda por gerenciamento do fluxo de energia entre os recursos energéticos distribuídos e cargas para otimizar o desempenho geral do sistema. Nesse sentido, este trabalho tem como objetivo apresentar os resultados do uso de três métodos de otimização distribuída, Consenso, Difusão e Difusão Exata, aplicados para a solução do despacho ótimo de uma microrrede em cenários distintos. Esses métodos apresentam características mais compatíveis ao novo modelo de sistemas elétricos e os seus desempenhos são comparados a fim de verificar as características mais vantajosas quanto ao aspecto de parâmetros de esforço computacional, velocidade de convergência e privacidade da informação. Além disso, os métodos são aprimorados para garantir melhor desempenho e equilíbrio dos recursos distribuídos por meio de técnicas que tornam os métodos mais robustos e contribuem para um menor esforço computacional do processo ao diminuir o número de iterações necessárias até a convergência. Os métodos de otimização demonstraram resultados adequados em diferentes cenários propostos e foram, então, implementados para o planejamento de abastecimento de cargas durante 24 horas a partir de previsões de geração renovável e carga. O método de Difusão mostrou-se eficiente em ambos os modos de operação da microrrede, ilhado e conectado, com poucas iterações e boa velocidade de convergência, além de requerer um menor esforço computacional analisado a partir do número de iterações até a convergência e número de operações por iteração. Para Difusão Exata, verificou-se uma mudança de padrão de acordo com o modo de operação da microrrede e com a matriz de pesos utilizada, sendo suas características mais favoráveis quanto aos aspectos de velocidade de convergência e esforço computacional no modo ilhado, com as matrizes *Hasting Rules* e *Averaging Rule*. Por fim, o Consenso apresentou características de velocidade de convergência inferiores aos demais métodos no modo ilhado, diferentemente do modo conectado em que se aproximou da Difusão.

Palavras-chave: microrredes; otimização; despacho econômico; consenso; difusão.

ABSTRACT

Electric grids are undergoing a period of significant transition in the generation and use of electric energy, which implies the need for regulatory and technological changes. Among the aspects that mark this transformation, there is the diffusion of distributed energy resources, the greater need for communication technologies and the more active role of the consumer. In this sense, microgrids stand out, the most recent grid technologies, marking the new models of electric power distribution systems. The distributed and varied nature of the energy resources of a microgrid demands management of the flow of energy between distributed energy resources and loads to optimize overall system performance. In this sense, this work aims to present three distributed optimization methods, Consensus, Diffusion and Exact Diffusion, applied to solve the optimal dispatch of a microgrid in different scenarios. These methods present characteristics more compatible to the new model of electrical systems and their performances are compared in order to verify the most advantageous characteristics regarding the aspect of parameters of computational effort and information privacy. In addition, the methods are improved to ensure better performance and balance between distributed resources through techniques that make the methods more robust and contribute to a lower computational effort in the process. The proposed optimization methods showed adequate results in different scenarios and were then implemented for 24-hour load supply planning based on renewable generation and load forecasts. The Diffusion method proved to be efficient in both the islanded and connected microgrid operation modes, with few iterations and good convergence speed, in addition to requiring little computational effort analyzed from number of iterations to convergence and number of operations per iteration. For Exact Diffusion, there was a pattern change according to the microgrid's operating mode and the weight matrix used, its characteristics being more favorable in terms of convergence speed and computational effort in islanded mode with Hasting Rules and Averaging Rules matrices. Finally, the Consensus presented characteristics of speed of convergence and computational effort much lower than the other methods in the islanded mode, unlike the connected mode in which it approached the Diffusion.

Keywords: microgrids; optimization; economic dispatch; consensus; diffusion.

LISTA DE FIGURAS

Figura 1 – Produção de Energia Elétrica por Tipo de Fonte de 1986 a 2020	21
Figura 2 – Produção de Energia Elétrica por Fonte	21
Figura 3 – Evolução da Fonte Solar Fotovoltaica no Brasil	22
Figura 4 – Arquitetura de uma Microrrede	24
Figura 5 – Rede Multiagente de uma Microrrede	30
Figura 6 – Grafo Ponderado	31
Figura 7 – Redes Fortemente e Fracamente Conectadas	32
Figura 8 – Configuração de Rede Multiagente para gerenciamento de recursos	33
Figura 9 – Relação entre as Classes de Matrizes	38
Figura 10 – Linha do Tempo de Referências	41
Figura 11 – Relação entre o SOC e Custo Incremental	45
Figura 12 – Função Utilidade	47
Figura 13 – Rede de Agentes no Modo Ilhado	51
Figura 14 – Rede de Agentes no Modo Conectado	52
Figura 15 – <i>Flags</i> sinalizadoras de ultrapassagem de potência	60
Figura 16 – Fluxograma da Atualização do Custo Incremental	61
Figura 17 – Etapa de Atualização de Potências	62
Figura 18 – Fluxograma do Processo de Despacho Econômico	62
Figura 19 – Resultados Cenário 1	67
Figura 20 – Resultados Cenário 2	68
Figura 21 – Resultados Cenário 3	70
Figura 22 – Resultados Cenário 4	72
Figura 23 – Resultados Cenário 5	73
Figura 24 – Previsão de Geração Renovável e Carga	74
Figura 25 – Resultado Cenário 6	75
Figura 26 – Operações de uma iteração	77

LISTA DE TABELAS

Tabela 1 – Ganho de <i>feedback</i> dos agentes no modo ilhado	59
Tabela 2 – Ganho de <i>feedback</i> dos agentes no modo conectado	59
Tabela 3 – Parâmetros Agente Geração Despachável	64
Tabela 4 – Parâmetros Agente Bateria	65
Tabela 5 – Parâmetros Função Utilidade	65
Tabela 6 – Cenários Simulados - Modo Ilhado	66
Tabela 7 – Resultados Cenário 1	66
Tabela 8 – Resultados Cenário 2	68
Tabela 9 – Resultados Cenário 3	69
Tabela 10 – Cenários Simulados - Modo Conectado	70
Tabela 11 – Resultados Cenário 4	71
Tabela 12 – Resultados Cenário 5	73

LISTA DE ABREVIATURAS E SIGLAS

RED	Recursos Energéticos Distribuídos
GD	Geração Distribuída
VE	Veículos Elétricos
MR	Microrrede
PNE	Plano Nacional de Energia
RDA	Redes de Distribuição Ativas
SEP	Sistema Elétrico de Potência
PCC	Ponto de Comum Conexão
PSO	<i>Particle Swarm Optimization</i>
AG	Algoritmo Genético
ATC	<i>Adapt Then Combine</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Motivação	16
1.2	Objetivos	17
1.3	Contribuições e Publicações	18
<i>1.3.1</i>	<i>Contribuições</i>	<i>18</i>
<i>1.3.2</i>	<i>Publicações</i>	<i>18</i>
1.4	Estrutura do Trabalho	19
2	GERAÇÃO DISTRIBUÍDA, SISTEMAS DE ARMAZENAMENTO DE ENERGIA E MICRORREDES	20
2.1	Introdução	20
2.2	Geração Distribuída	20
2.3	Sistemas de Armazenamento de Energia	22
2.4	Microrredes	23
<i>2.4.1</i>	<i>Arquitetura de uma Microrrede</i>	<i>24</i>
<i>2.4.2</i>	<i>Modos de Operação de uma Microrrede</i>	<i>25</i>
<i>2.4.3</i>	<i>Informações que Afetam a Operação de uma Microrrede</i>	<i>25</i>
2.5	Considerações Finais	26
3	MÉTODOS DE OTIMIZAÇÃO PARA O DESPACHO DE MICRORREDES	27
3.1	Introdução	27
3.2	Despacho Econômico de Microrrede	27
3.3	Métodos de Otimização Centralizada	28
3.4	Redes Multiagentes e Processamento Distribuído	29
<i>3.4.1</i>	<i>Redes Conectadas e Teoria dos Grafos</i>	<i>30</i>
3.5	Estratégias de Otimização Distribuída	33
<i>3.5.1</i>	<i>Consenso</i>	<i>33</i>
<i>3.5.2</i>	<i>Revisão Bibliográfica: Consenso e Despacho Econômico de Microrredes</i>	<i>35</i>
<i>3.5.3</i>	<i>Difusão</i>	<i>36</i>
<i>3.5.4</i>	<i>Revisão Bibliográfica: Difusão e Despacho Econômico de Microrredes</i>	<i>37</i>
<i>3.5.5</i>	<i>Difusão Exata</i>	<i>37</i>

3.5.6	<i>Revisão Bibliográfica: Difusão Exata e Despacho Econômico de Microrredes</i>	39
3.6	Contribuições e Principais fontes	39
3.7	Considerações Finais	41
4	FORMULAÇÃO DO PROBLEMA E MODELAGEM DOS AGENTES DA MICRORREDE	43
4.1	Introdução	43
4.2	Modelagem dos Agentes	43
4.2.1	<i>Agente Geração Despachável</i>	43
4.2.2	<i>Agente Geração Renovável</i>	44
4.2.3	<i>Agente Bateria</i>	44
4.2.4	<i>Agente Carga</i>	45
4.2.4.1	<i>Agentes Carga no Modo Ilhado</i>	46
4.2.4.2	<i>Agentes Carga no Modo Conectado</i>	47
4.2.5	<i>Agente Rede</i>	47
4.3	Modelagem do Despacho Econômico em Microrredes	48
4.3.1	<i>Formulação do Problema</i>	48
4.3.1.1	<i>Função Objetivo para o Modo Ilhado</i>	48
4.3.1.2	<i>Função Objetivo para o Modo Conectado</i>	49
4.3.2	<i>Operação Ótima</i>	50
4.3.3	<i>Consenso aplicado ao Despacho Ótimo em Microrredes</i>	51
4.3.4	<i>Difusão aplicado ao Despacho Ótimo em Microrredes</i>	54
4.3.5	<i>Difusão Exata para o Despacho Ótimo em Microrredes</i>	55
4.3.6	<i>Otimização do Ganho de Feedback</i>	57
4.4	Desenvolvimento do Despacho Ótimo em Microrredes	60
4.5	Considerações Finais	62
5	CENÁRIOS SIMULADOS E RESULTADOS	64
5.1	Introdução	64
5.2	Configuração dos Agentes e Parâmetros Analisados	64
5.3	Cenários de Modo Ilhado	65
5.3.1	<i>Cenário 1</i>	65
5.3.2	<i>Cenário 2</i>	67
5.3.3	<i>Cenário 3</i>	68

5.4	Cenários de Modo Conectado	69
5.4.1	<i>Cenário 4</i>	70
5.4.2	<i>Cenário 5</i>	71
5.4.3	<i>Cenário 6</i>	72
5.5	Comparação dos Métodos quanto ao Esforço Computacional	75
5.6	Comparação dos Métodos quanto à Privacidade	76
5.7	Considerações Finais	77
6	CONCLUSÃO E TRABALHOS FUTUROS	79
6.1	Conclusões	79
6.2	Trabalhos Futuros	80
	REFERÊNCIAS	81
	APÊNDICES	85
	ANEXOS	104

1 INTRODUÇÃO

Mudanças normativas, regulatórias e tecnológicas vêm marcando fortemente o setor elétrico ensejadas essencialmente pela valorização da sustentabilidade ambiental e pelo aumento da demanda por eletricidade. Impulsionado por essas tendências, as redes elétricas vêm se modernizando e migrando para implantação de Redes Elétricas Inteligentes (REI) ou *Smart Grids*. Modernizar a rede para torná-la ‘mais inteligente’ envolve o uso de tecnologias, equipamentos e controles de ponta que melhoram a conectividade, eficiência, segurança e sustentabilidade da rede elétrica (FARHANGI, 2010), (RAYA-ARMENTA *et al.*, 2021).

A modernização das redes elétricas inclui a disseminação de Recursos Energéticos Distribuídos (RED) que abrangem a Geração Distribuída (GD) de energia, o armazenamento distribuído de energia, os Veículos Elétricos (VE) e o gerenciamento pelo lado da demanda de energia distribuída. A redução nos custos de investimentos, a maior disseminação das tecnologias de telecomunicação e controle, e o papel mais ativo dos consumidores justificam uma acelerada inserção dos RED (EPE, 2018). O *World Energy Council* (2017) aponta que, no período entre 2017 e 2025, deve-se observar a transição de sistemas elétricos predominantemente centralizados para sistemas híbridos, caracterizando uma disruptura do tradicional sistema de grandes centrais de geração localizadas distantes dos centros de carga.

A utilização de RED contribui para uma maior flexibilidade e confiabilidade da rede elétrica, redução dos picos de carga e das perdas de energia, além de postergar investimentos em infraestrutura de transmissão e geração de grande porte. Entretanto, a grande diversidade de recursos gera uma maior necessidade de monitoramento em tempo real, além de melhores tecnologias de automação, controle e estimação de variáveis de estado a fim de exercer um adequado gerenciamento no uso dos RED e da rede elétrica. (HUANG *et al.*, 2012).

Diante da grande diversidade de RED disponíveis é preciso analisar os mecanismos capazes de valorizar economicamente os benefícios destes recursos. A estruturação e análise dos sinais econômicos dos agentes conectados às redes de distribuição de energia direcionam as decisões no sentido de obter o melhor aproveitamento destes recursos sem comprometer a segurança e confiabilidade do suprimento da rede (EPE, 2018).

No cerne dessa inserção em massa de RED nas redes de distribuição, ainda cabe destacar a criação de maiores incertezas sobre a demanda e a geração variável da energia elétrica. Além disso, a característica distribuída desses recursos exige a reformulação dos métodos e ferramentas de planejamento da geração e transmissão com as redes de distribuição.

A evolução das redes de distribuição envolve também a inserção de mecanismos inteligentes para integração e gerenciamento dos múltiplos RED. Nesse contexto, surgem as Microrredes como perspectiva futura da rede elétrica que implementa efetivamente todas as tecnologias de rede inovadoras possíveis.

Uma Microrrede (MR) consiste em um grupo semi-autônomo de RED e cargas interconectadas que atuam como um único sistema controlável com relação à rede externa principal, podendo operar em modo conectada ou desconectada da rede (LASSETER *et al.*, 2002). Nas MR, configuram-se agregadores de RED, formando-se plantas virtuais e que despacham no mercado de eletricidade (EPE, 2018). Assim, a potencialização e otimização dos benefícios econômicos proporcionados pelos recursos de uma MR devem ser analisadas.

Um dos aspectos relevantes ao analisar-se a potencialização de benefícios econômicos proporcionados por uma MR é o despacho econômico. O despacho econômico trata do uso ótimo dos recursos de um sistema elétrico para redução do custo total de atendimento à demanda, levando em consideração as restrições operacionais dos elementos que compõem a rede.

Diversos métodos de otimização têm sido aplicados para obtenção do despacho econômico ótimo de uma MR. Neste trabalho, três métodos de otimização de arquitetura distribuída são aplicados ao problema de despacho econômico de um MR e comparados quanto aos resultados obtidos, visando a obtenção de valores ótimos de despacho econômico através de formas mais eficientes.

1.1 Motivação

O contínuo crescimento da participação de RED e MR traz novos desafios, exigindo a adaptação quanto ao planejamento, desenhos de mercado e arcabouço normativo-regulatório vigentes de forma a potencializar os benefícios de uma rede ativa (FUENTES-BRACAMONTES, 2016).

De acordo com o Relatório do Plano Nacional de Energia (PNE) de 2050, a descentralização do setor elétrico pode ser analisada sob três perspectivas:

- Tecnológica: está associada à complexidade para operação dos recursos de forma harmônica;
- Desenhos de mercado: está associada à necessidade de criação de um ambiente capaz de promover uma decisão eficiente dos agentes;
- Novos negócios: está relacionado aos obstáculos associados ao papel da rede de

distribuição e ao surgimento de novos agentes.

Na perspectiva da descentralização, alguns desafios são apontados pelo PNE 2050 como focos de concentração de análises e estudos, são eles:

- Nova realidade de operação dos sistemas de distribuição devido à inserção dos RED, o que acarreta uma maior quantidade de agentes e requer um papel mais proativo das transmissoras e distribuidoras na gestão e operação das redes.
- Valoração dos novos serviços de forma a maximizar os benefícios sistêmicos para o sistema elétrico. Assim, deve-se otimizar a operação e os custos, adaptando-se a sinalização econômica para os serviços de forma a induzir novos investimentos e novos serviços e a estimular os consumidores a responderem ativamente, destacando-se os aspectos locacional e temporal diversos dos serviços elétricos.

No cenário exposto, verifica-se a necessidade da proposição de abordagens compatíveis com o modelo descentralizado atual e que permitam a extração dos benefícios da operação de uma rede ativa e a identificação dos custos de oportunidade partilhados pelos múltiplos agentes interessados. Essa análise contribui para o embasamento e criação de regulação pertinente, além de estudos de expansão da rede de distribuição (OLIVEIRA, 2017).

As Microrredes constituem uma das tendências da próxima geração de redes elétricas através das redes elétricas inteligentes ou *Smart Grids*. As MR fazem uso de moderna tecnologia de informação e comunicação de forma a possibilitar a otimização local de geração, armazenamento e demanda, extraindo benefícios da diversidade e flexibilidades de seus recursos, criando valor para o sistema e para seus usuários. Assim, as MR constituem um desafio ao paradigma atualmente verificado no setor elétrico, sendo dotadas de uma estrutura descentralizada para integração entre geração e demanda. Faz-se necessário, portanto, analisar as possibilidades, vantagens e desvantagens das MR e seus recursos quanto ao aspecto econômico e mercadológico.

1.2 Objetivos

Este trabalho tem o objetivo de apresentar um sistema de despacho econômico para microrredes com múltiplos REDs baseado nos métodos de Otimização Distribuído de Consenso, Difusão e Difusão Exata.

Os objetivos específicos deste trabalho contemplam:

- Modelar os elementos da MR como agentes no problema de despacho econômico;
- Implementar em Python um modelo de despacho econômico de uma MR,

baseando-se nos métodos de otimização Consenso, Difusão e Difusão Exata;

- Obter o despacho econômico ótimo da MR para diferentes cenários, com previsão horária ao longo de 24h para a geração renovável e demanda, para os modos de operação ilhado e conectado;
- Comparar o desempenho dos métodos de otimização quanto aos aspectos de velocidade de convergência, esforço computacional, privacidade de informação e resultados obtidos;
- Propor estratégias para aperfeiçoar os métodos de otimização quanto aos aspectos de convergência e esforço computacional.

1.3 Contribuições e Publicações

1.3.1 Contribuições

As principais contribuições deste trabalho são:

- Desenvolvimento de modelos de Despacho Econômico de MR baseados em estratégias distribuídas para os modos ilhado e conectado contendo os modelos de todos os recursos energéticos inerentes a uma MR;
- Adoção de um ganho de *feedback* variável obtido por meio de Algoritmo Genético para tornar mais eficiente a otimização através dos métodos distribuídos analisados;
- Análise de quatro diferentes tipos de matrizes de adjacências no algoritmo de Difusão Exata.
- Análise comparativa da eficiência computacional dos métodos através de diferentes parâmetros de esforço computacional, velocidade de convergência e privacidade da informação.

1.3.2 Publicações

Durante o desenvolvimento deste trabalho foram realizadas 2 publicações, são elas:

- "Despacho Ótimo de Microrredes: uma Comparação dos Métodos de Otimização Distribuída de Consenso, Difusão e Difusão Exata"(Congresso Brasileiro de Automática 2022);
- "Economic Dispatch of a Microgrid using the Distributed Optimization Methods

of Consensus and Diffusion"(IEE/IAS International Conference on Industry Applications).

1.4 Estrutura do Trabalho

Este trabalho está dividido em seis capítulos, a saber:

- Capítulo 1: o trabalho é contextualizado com a apresentação de motivação e objetivos, realçando sua importância no advento das redes inteligentes.
- Capítulo 2: é apresentada a revisão literária e fundamentação teórica sobre MR, seus elementos e forma de funcionamento. Além disso, é abordado o problema de despacho econômico para MR, englobando os principais desafios, questões técnicas e operacionais.
- Capítulo 3: são apresentados a utilização de redes multiagentes em problemas como a minimização de custos, bem como a aplicação dos métodos de otimização distribuída de Consenso, Difusão e Difusão Exata, que são o foco desse estudo. Além disso, é apresentada uma revisão bibliográfica abordando os métodos de otimização aplicados ao problema de despacho econômico em microrredes verificados na literatura, bem como as principais estratégias e fontes adotadas nesse estudo.
- Capítulo 4: são apresentadas as modelagens de custo dos agentes que representam os recursos de uma microrrede bem como a aplicação das estratégias de otimização distribuída ao problema de despacho ótimo em microrredes, além das estratégias desenvolvidas neste estudo para tornar esse processo mais eficiente.
- Capítulo 5: são apresentados e discutidos os resultados dos métodos de otimização distribuídos executados para diferentes situações de operação da MR, bem como para diferentes níveis de geração renovável e de carga.
- Capítulo 6: são apresentadas as conclusões do presente trabalho e as propostas de desenvolvimento futuro.

2 GERAÇÃO DISTRIBUÍDA, SISTEMAS DE ARMAZENAMENTO DE ENERGIA E MICRORREDES

2.1 Introdução

Neste capítulo será feita uma revisão bibliográfica abordando os principais conceitos relativos a MR e suas principais tecnologias, tais quais geração distribuída (GD), sistemas de armazenamento e resposta a demanda. Além disso, serão abordados aspectos de despacho econômico.

2.2 Geração Distribuída

As redes elétricas estão passando por um período de transição estimulando a inserção de tecnologias emergentes capaz de lidar com questões ambientais, aumento na eletrificação de cargas e oferta de novos serviços.


Na Figura 1 é apresentada a produção de energia elétrica por fonte em que é possível notar o reflexo do processo de transição das redes elétricas através do notório aumento de geração de energia elétrica através das fontes eólica e solar, que anteriormente se apresentavam como fontes insignificantes.

Na Figura 2 é ilustrada a produção de energia elétrica no Brasil por fonte nos anos de 1973 e 2018. Nessa figura nota-se que as fontes eólica e solar, que são as mais significativas dentro da classificação de outras fontes, contribuem de forma notória com a produção de energia elétrica, no Brasil com 9,8% no ano de 2018 em um comparativo com o ano de 1973 que apresentou uma produção bem menor com a contribuição de apenas 0,6% de outras fontes. Na Figura 3, destaca-se a evolução da fonte solar fotovoltaica, enfatizando-se a sua grande participação na geração distribuída (GD) no Brasil.

A participação de fontes eólica e solar PV nas redes elétricas de distribuição sinaliza a presença da Geração Distribuída renovável. A GD é definida como uma fonte de potência elétrica conectada à rede de distribuição ou diretamente na unidade consumidora, que se diferencia da geração convencional que é caracterizada por grandes unidades geradoras dispostas de forma centralizada (ACKERMANN *et al.*, 2001). No Brasil, ações regulatórias, como as que estabelecem a possibilidade de compensação da energia excedente injetada na rede da concessionária, incentivaram o crescimento da micro e mini geração distribuída.

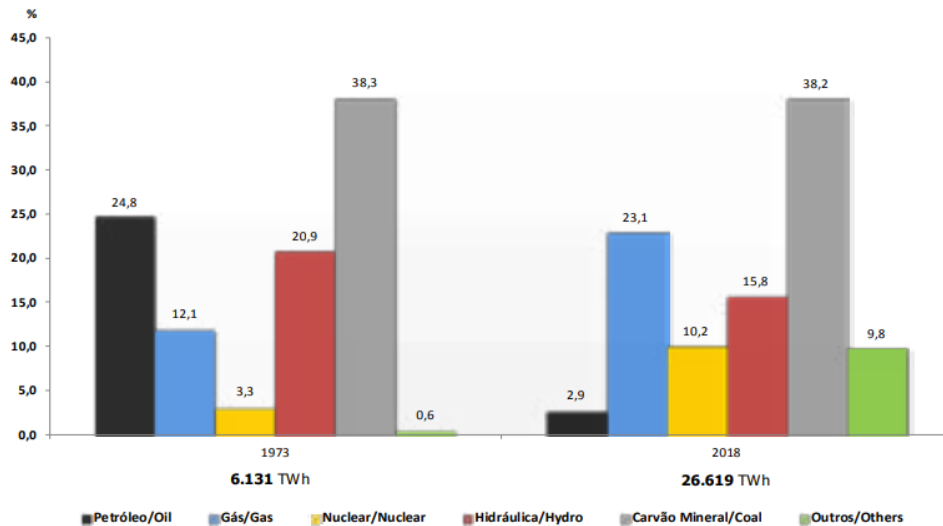
Alguns aspectos essenciais diferenciam positivamente a GD da geração centralizada

Figura 1 – Produção de Energia Elétrica por Tipo de Fonte de 1986 a 2020



Fonte: (PETROLEUM, 2022)

Figura 2 – Produção de Energia Elétrica por Fonte




tradicional, são eles:

- Possui maior valor locacional;
- Pode ser agregada de diferentes formas, potencializando o papel de agentes agregadores;
- Permite modelos de negócio inovadores, dificilmente replicáveis na escala de grandes centrais.

A expansão da GD, embora apresente desafios técnicos e operacionais, sinaliza características atrativas, tais quais: tempo de implantação reduzido, menor risco de investimento e adaptabilidade à dinâmica de evolução do consumo (OLIVEIRA, 2017).

Figura 3 – Evolução da Fonte Solar Fotovoltaica no Brasil



Fonte: (ABSOLAR, 2022)

2.3 Sistemas de Armazenamento de Energia

A expansão da GD é proveniente em grande parte por fontes renováveis e não-despacháveis. Os recursos renováveis variáveis apresentam desafios devido à flutuação da produção de eletricidade. Tal característica demonstra que o sistema pode ter uma descompensação entre geração e demanda de carga.

No sistema elétrico, para manter a estabilidade do sistema, deve haver balanço entre geração e demanda. Nesse sentido, dispositivos de armazenamento de energia têm sido apontados como um elemento chave para integração e expansão de recursos de geração renováveis e distribuídos (EYER; COREY, 2010). Os sistemas de armazenamento contribuem para o balanço de potência do sistema, absorvendo a energia excedente da geração ou disponibilizando energia quando o sistema apresenta déficit de geração.

Abordando o aspecto econômico, pode-se investir em dispositivos de armazenamento para utilização em horário de pico contribuindo para diminuição de custos com energia, além

da utilização em situações de indisponibilidade da rede principal. Logo, a reestruturação do sistema elétrico de forma confiável e com qualidade passa pela efetividade dos sistemas de armazenamento de energia elétrica.

2.4 Microrredes

A inserção de GD, sistemas de armazenamento e outros RED marcam o novo modelo de redes elétricas que passa a apresentar característica ativa, com fluxo de potência bidirecional, caracterizando as Redes de Distribuição Ativas (RDA). O avanço das RDAs requer a implementação de novos conceitos e tecnologias, sendo um dos mais promissores o conceito de Microrredes, que incluem em sua estrutura os recursos citados de forma integrada e harmônica (HATZIARGYRIOU, 2014).

Atualmente, existe uma demanda social pelo fornecimento confiável e sustentável de energia elétrica, o que vem influenciando a formação de microrredes nos sistemas de distribuição de energia elétrica. O Departamento de Energia dos EUA define Microrrede como um grupo de cargas e recursos energéticos distribuídos (REDs) interligados dentro de limites elétricos claramente definidos, que atuam como uma única entidade controlável em relação à rede e podem operar em conectado à rede e modo ilha (RAYA-ARMENTA *et al.*, 2021). Essas infraestruturas unem tecnologias de geração e de armazenamento de energia e marcam um novo modelo de sistema elétrico capaz de tornar o consumidor mais ativo na gestão da produção e da carga e fornecer vantagens econômicas

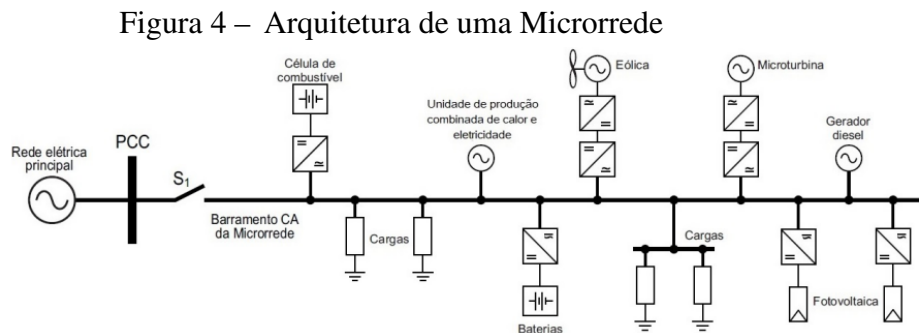
Na literatura são encontradas diversas definições de microrredes e dentre estas a de (MARNAY, 2015):

Microrredes são sistemas de distribuição de energia elétrica contendo demandas e recursos energéticos distribuídos (tais como geração distribuída, sistemas de armazenamento ou demandas controláveis) que podem operar de forma controlada e coordenada, enquanto opera em modo ilhado ou conectado com a rede principal de energia.

A estrutura de uma MR é caracterizada pela atuação de dispositivos inteligentes responsáveis por monitorar o estado do sistema e reconfigurar equipamentos de acordo com vários requisitos. Além disso, estão presentes características como eficiência, resiliência, dinamicidade e flexibilidade. Os diversos recursos de uma MR são agrupados, operando como um único ativo dentro do Sistema Elétrico de Potência (SEP), facilitando sua integração à rede elétrica (SIOSHANSI, 2012).

2.4.1 Arquitetura de uma Microrrede

Na Figura 4 é apresentada a arquitetura básica de uma MR em que constam suas tecnologias típicas: geração distribuída, dispositivo de armazenamento de energia, cargas controláveis e dispositivos para o controle destes elemento. A conexão da MR com a rede principal externa é estabelecida através do Ponto de Conexão (PCC). O PCC constitui um aspecto marcante de MR e contém um dispositivo que atua nas manobras de ilhamento e resincronização, além de atuar na proteção.



Fonte: (AZEVEDO, 2011)

As fontes de GD das MR são em sua maioria baseadas em fontes renováveis de natureza intermitente (fotovoltaica e eólica). No entanto, outras fontes despacháveis (microturbina, célula combustível, gerador diesel) também são empregadas para o aumento da confiabilidade do fornecimento de energia. Além disso, são utilizados dispositivos armazenadores de energia, como banco de baterias, super capacitores e *flywheels*, oferecendo maior flexibilidade à operação do sistema (ALMEIDA, 2019). Assim, diante da grande variedade de recursos disponíveis em uma MR, a integração harmoniosa e vantajosa desses recursos requer um controle e coordenação adequados.

As MR também contêm comumente em sua estrutura dispositivos de controle de carga, fontes e armazenamento de energia. Em arquitetura de controle centralizada, os dispositivos de controle local se comunicam com o dispositivo responsável pelo controle central do Sistema Microrrede favorecendo uma utilização mais vantajosa dos recursos da MR (HATZIRGYRIOU, 2014).

Quando projetada adequadamente, uma rede elétrica regional que combina grandes usinas centrais e microrredes distribuídas pode ser construída com: menor custo total de capital, menor geração instalada, maior fator de capacidade em todos os ativos e maior confiabilidade.

2.4.2 Modos de Operação de uma Microrrede

Existem dois modos de operação para as MR, são eles:

- Modo Conectado: a MR está conectada eletricamente à rede principal de distribuição, possibilitando o intercâmbio de potência (HATZIARGYRIOU, 2014);
- Modo Ilhado: a MR funciona de forma autônoma e isolada da rede principal. Essa desconexão é realizada via PCC, podendo ser planejada ou devido à detecção de alguma falta na rede principal (HATZIARGYRIOU, 2014).

A capacidade de ser isolada da rede principal torna as MR resilientes, e permite a entrega de serviços que tornam a rede mais competitiva. Ao desconectar-se da rede em emergências, uma MR pode continuar atendendo sua carga quando a rede principal estiver inativa e servir a comunidade ao redor, fornecendo uma plataforma para apoiar serviços críticos. Entretanto, a operação ilhada da MR é mais complexa no que diz respeito ao balanço de potência para garantir estabilidade, e à manutenção dos níveis de tensão e frequência dentro dos limites. Em uma MR com predominância de fontes renováveis variáveis, os dispositivos de armazenamento de energia desempenham papel fundamental para a operação segura da MR.

2.4.3 Informações que Afetam a Operação de uma Microrrede

A multiplicidade de recursos de uma microrrede pode proporcionar muitos benefícios aos usuários e operadores de uma rede, proporcionando maior confiabilidade, disponibilidade e redução de custos. Entretanto, muitas informações afetam a operação da microrrede, tornando o seu controle mais complexo e bastante discutido.

O conjunto de todas as informações que potencialmente afetam a operação da microrrede é enorme e inclui detalhes tarifários, desempenho dos equipamentos, condições e previsões climáticas que afetam as fontes renováveis e a demanda, detalhes e previsões de carga e modelos térmicos da microrrede. Segundo (FIRESTONE; MARNAY, 2005), os principais fatores que interferem no gerenciamento de recursos de uma microrrede são os seguintes:

- Informações tarifárias e regulamentares: a minimização do custo total de energia implica na comparação entre os custos de energia da autogeração e da compra da concessionária e, além disso, restrições regulatórias podem restringir determinadas operações dos REDs.
- Especificações dos equipamentos: cada equipamento tem uma faixa de níveis

operacionais e de desempenho que variam de acordo com as suas capacidades e com fatores externos.

- Previsões e dados atmosféricos: o monitoramento das condições meteorológicas pode ser usado para a previsão de longo e curto prazo para fontes de geração intermitente e demanda de um local.
- Previsão de Carga: os requisitos de carga devem ser atendidos e o planejamento do gerenciamento da microrrede pode se beneficiar da previsão de carga com base nos dados históricos.

2.5 Considerações Finais

Este capítulo apresentou conceitos importantes referentes a microrredes e seus principais recursos característicos e modos de funcionamento, apontando os fatores que influenciam na operação diante à diversidade de recursos energéticos. Dentre esses fatores foi apontada a maior complexidade de gerenciamento e despacho econômico dos recursos de uma microrrede, cujos meios de solucionar o problema de despacho serão abordados no Capítulo 3.

3 MÉTODOS DE OTIMIZAÇÃO PARA O DESPACHO DE MICRORREDES

3.1 Introdução

Diante da diversidade de REDs em uma MR, verifica-se uma mudança de padrão do mercado de energia, marcado por uma quantidade maior de interações entre fontes de geração distribuída, rede e carga. Sendo o despacho econômico uma questão chave na operação dos sistemas elétricos, o controle e gerenciamento de dispositivos distribuídos de forma segura e econômica tornou-se um problema bastante discutido na literatura. Os problemas tradicionais de despacho econômico adotam os métodos de controle centralizado que vêm sendo substituídos pelo processamento distribuído. A adoção de redes de agentes para a cooperação e processamento de informações de forma descentralizada constitui um modelo compatível com os métodos de otimização distribuída. Neste capítulo serão abordadas as principais estratégias de otimização adotadas para o despacho econômico, incluindo abordagens centralizadas e distribuídas, com destaque aos métodos distribuídos do Consenso, Difusão e Difusão Exata aplicados a uma rede de agentes que modelam os REDs. Para cada abordagem de otimização, será feita uma revisão bibliográfica apontando estudos que utilizaram os respectivos métodos na solução do problema de despacho em MRs.

3.2 Despacho Econômico de Microrrede

No contexto de sistemas elétricos, o despacho ótimo é um problema de otimização, caracterizado pela busca do custo mínimo de operação da rede através do manejo de potência entre os recursos energéticos disponíveis para o atendimento da demanda, satisfazendo as restrições técnicas dos recursos e da rede elétrica. Os REDs possuem formulações de custo distintas de acordo com suas características, devendo o problema de despacho econômico distribuir a demanda total entre essas unidades, além de fornecer o custo incremental do sistema. O custo incremental, também denominado custo marginal, representa o valor monetário para abastecer o aumento de mais uma unidade de potência demandada (GALIANA; CONEJO, 2009). Sendo o custo dos REDs associados à potência a ser fornecida, o custo incremental corresponderá à derivada da função que caracteriza o custo do recurso com relação à potência a ser fornecida.

O problema de despacho econômico dos recursos de uma MR está intrinsecamente ligado com a natureza dos RED, da demanda e com o ambiente regulatório vigente. Por ser

um problema de otimização, uma função objetivo deve ser definida para cada componente da MR que participa do despacho econômico. Diferentes abordagens podem ser adotadas para otimização de um problema, as quais podem ser avaliadas segundo a performance e o custo computacional associados à sua implementação. Em geral, os modelos computacionais empregados nos problemas de otimização são classificados como:

- Centralizados, baseados em métodos determinísticos (p.ex. Programação Linear Inteira Mista), heurísticos (p.ex., sistemas especialistas e lógica fuzzy) e meta-heurísticos (p.ex. *Particle Swarm Optimization* (PSO), Algoritmo Genético (AG) etc.);
- Hierárquicos ou parcialmente distribuídos (p.ex. sistemas multiagentes);
- Distribuídos (p.ex., sistemas multiagentes, consenso, difusão e difusão exata)

Este trabalho faz uso de modelo de otimização distribuído, que aplica os algoritmos de consenso, difusão e difusão exata. No capítulo 4 a modelagem do despacho econômico ótimo de MR é detalhado.

3.3 Métodos de Otimização Centralizada

Existe uma vasta literatura sobre despacho econômico ótimo. Muitos métodos centralizados foram propostos para o controle ideal do despacho dos recursos de uma rede elétrica. Dentre os métodos adotados, destacam-se métodos de Programação Linear Inteira Mista utilizadas em um modelo de controle preditivo que utiliza máquinas vetoriais de suporte em (PARISIO *et al.*, 2014). Além disso, outra estratégia de despacho adotada em alguns estudos é o Algoritmo Genético como em (SHADMAND; BALOG, 2014), (BAKIRTZIS *et al.*, 1994) e (CHIANG, 2005). A otimização por Enxame de Partículas também é bastante adotada para o despacho ótimo de recursos de uma rede conforme (LI *et al.*, 2015) e (KUO, 2008). Outro método centralizado empregado para solucionar o despacho em Microrredes é o Algoritmo Imperialista Competitivo, aplicado em (NIKMEHR; RAVADANEGH, 2016) para múltiplas MRs. Alguns métodos computacionais também foram adotados para o problema de despacho como o Método de Busca Direta em (CHEN; CHEN, 2001) e através de Inteligência Artificial Integrada em (LIN *et al.*, 2001).

As estratégias de otimização com abordagens centralizadas têm sido eficazes para os sistemas convencionais de energia. Entretanto, para o atual modelo de rede elétrica em transição através da inserção de múltiplos REDs e na aplicação em microrredes, os modelos de otimização

centralizada enfrentam alguns desafios, dentre os quais:

- Necessidade de um controlador central robusto para processar um grande volume de dados em pouco tempo, implicando no aumento significativo da sua carga de computacional e custos extras (RAHBARI-ASR; CHOW, 2014).
- Possibilidade de congestionamento de comunicação, comprometendo a realização da função *plug and play* (YANG *et al.*, 2013).
- Problema de tolerância à falha, o sistema torna-se mais vulnerável a falhas de ponto único (RAHBARI-ASR; CHOW, 2014).
- A proteção da privacidade dos dados dos consumidores e recursos tornou-se um ponto de preocupação (RAHBARI-ASR; CHOW, 2014).
- O desenvolvimento de sistemas ciber físicos tende a ser distribuído.
- Dificuldade para atender as necessidades das redes inteligentes no futuro (KHAI-TAN *et al.*, 2015).

Nos últimos anos, para se adequar às novas características das redes elétricas e à estrutura de uma microrrede, muitos estudos propõem a adoção de métodos de otimização distribuída para resolver o problema de despacho econômico. Uma alternativa compatível com o novo modelo de redes elétricas é o controle distribuído através de uma rede de entidades autônomas que interajam entre si para solucionar problemas complexos. Essa rede de multiagentes permite controlar sistemas adaptativos de grande escala, distribuídos e complexos através de sua autonomia e flexibilidade (JIAN *et al.*, 2019). Nesse sentido, nos próximos tópicos serão discutidos o modelo de redes multiagentes para controle distribuído, bem como estratégias de otimização distribuída, com destaque para os métodos de Consenso, Difusão e Difusão Exata.

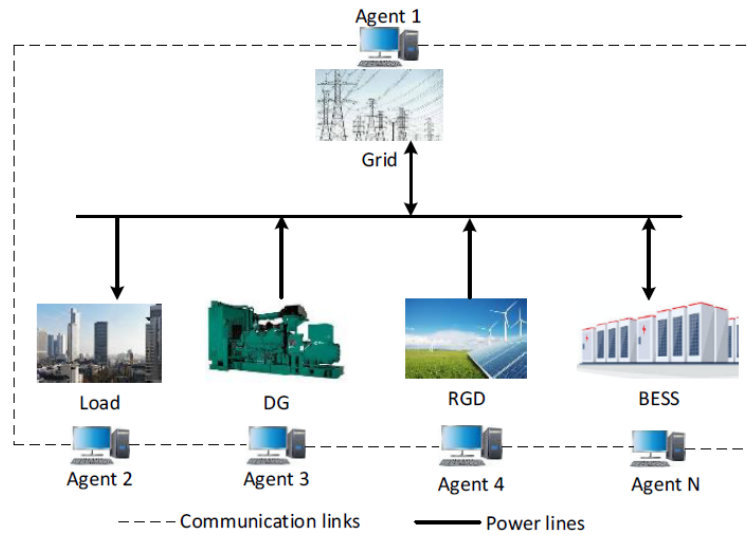
3.4 Redes Multiagentes e Processamento Distribuído

Sistemas complexos consistem em muitos elementos interagindo uns com os outros de forma desordenada com comportamentos aparentemente aleatórios. Estes sistemas dos mais variados ramos da ciência buscam reduzir a complexidade da coordenação entre unidades através do processamento de informações de forma descentralizada. Essas unidades constituem agentes que, embora desempenhem tarefas simples, através da interação mútua, constituem sistemas resilientes a falhas e capazes de ajustar o próprio comportamento em resposta a mudanças no ambiente. Muitos estudos têm sido realizados no sentido de desenvolver ferramentas que possibilitem o projeto de redes com habilidades sofisticadas de aprendizado e processamento,

capazes de resolver importantes tarefas, incluindo otimização de forma distribuída através de agentes que interagem localmente formando uma rede multiagente e que independem de centros de coleta e processamento de suas informações (SAYED *et al.*, 2014).

Na rede multiagente, os agentes são conectados por uma topologia e podem compartilhar informações apenas com seus vizinhos imediatos. A difusão contínua de informações pela rede permite que os agentes respondam em tempo real a desvios nas variáveis e a mudanças na topologia da rede. Além disso, são escaláveis, robustas e adequadas para o aprendizado com grandes conjuntos de dados. Essas redes também podem ser dotadas de habilidades cognitivas e sensoriais de seus agentes através das interações com seus vizinhos e mecanismos de feedback embutidos para adquirir e refinar informações (SAYED *et al.*, 2014). O agente pode adquirir informações diretamente do ambiente ou através de interações com seus vizinhos. As redes multiagentes, através do compartilhamento de informações, fornecem um ambiente favorável à aplicação de estratégias distribuídas de otimização, em particular, estratégias incrementais e estratégias envolvendo Consenso e Difusão. Na Figura 5 é apresentado um modelo de uma rede multiagente típica para a resolução do problema de despacho econômico de uma microrrede em que os REDs configuram agentes.

Figura 5 – Rede Multiagente de uma Microrrede



Fonte: (ALI *et al.*, 2020)

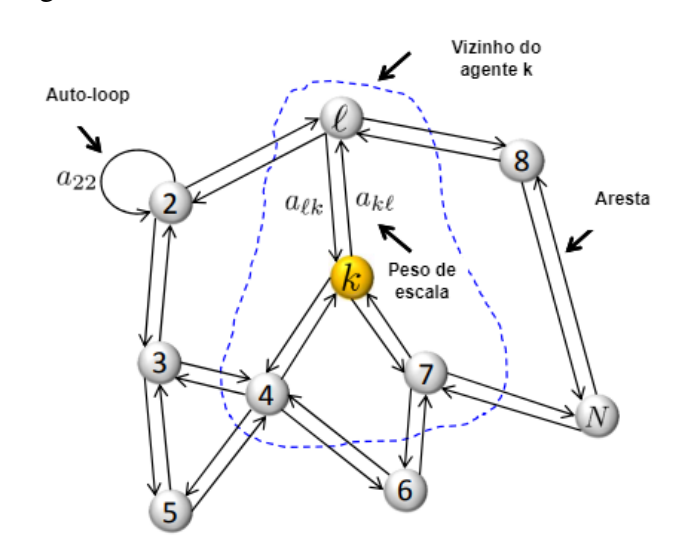
3.4.1 Redes Conectadas e Teoria dos Grafos

Uma rede conectada constituída por um número finito de agentes é caracterizada pela existência de pelo menos um caminho conectando dois agentes quaisquer. Os agentes (vértices)

podem ser conectados diretamente por uma aresta se forem vizinhos, ou, indiretamente, através de agentes intermediários. A topologia de uma rede multiagente pode ser descrita, então, em termos de grafos, vértices e arestas (SAYED *et al.*, 2014).

Um grafo é não direcionado quando se um agente k é vizinho de um agente l , e o agente l também é vizinho do agente k . Assim, dois agentes ou vértices vizinhos podem compartilhar informações através da aresta que os conecta. O fluxo de informações entre os agentes, entretanto, não é necessariamente simétrico, pois atribui-se um par de pesos não negativos (a_{kl} e a_{lk}) às arestas que conectam k e l . Esses pesos são utilizados para dimensionar os dados recebidos pelo agente vizinho, podendo ser interpretados como uma medida da confiança (SAYED, 2014). Na Figura 6 é representado um grafo ponderado.

Figura 6 – Grafo Ponderado

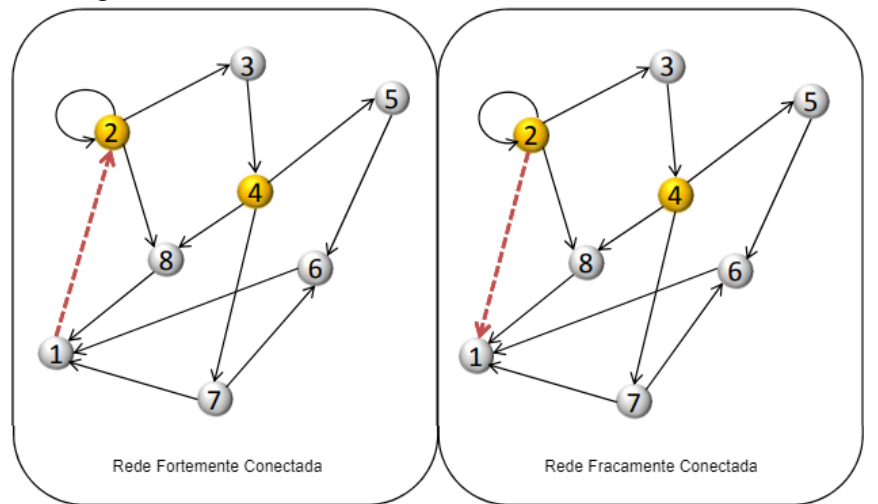


Fonte: (SAYED, 2014), adaptado

Uma rede multiagente é fortemente conectada caso haja pelo menos uma aresta de um agente em auto-loop com um peso de escala positivo, ou seja $a_{kk} > 0$ para algum vértice k . Isso indica que a informação pode fluir em ambas as direções entre quaisquer dois vértices distintos na rede. A suposição de uma rede fortemente conectada, portanto, garante que a informação fluirá entre quaisquer dois agentes na rede e que esse fluxo de informação será bidirecional, embora os caminhos pelos quais os fluxos ocorrem não precisam ser os mesmos e a ponderação da informação também pode ser diferente (SAYED *et al.*, 2014). Na Figura 7 é apresentada uma comparação entre uma rede fortemente conectada e uma rede fracamente conectada. Observa-se que para a rede fortemente conectada, entre dois agentes verificam-se caminhos ligando-os em ambas as direções com pesos positivos nas arestas ao longo desses caminhos. Comparativamente,

em redes fracamente conectadas, as informações podem não chegar em um determinado agente. Observa-se na Figura 7 que, diferentemente da rede fortemente conectada, as informações não podem ser recebidas pelo agente 2 de nenhum dos outros agentes da rede, embora as informações do agente 2 possam ser transmitidas a todos os outros agentes. Além disso, o agente 1 está apenas recebendo informações.


Figura 7 – Redes Fortemente e Fracamente Conectadas



Fonte: (SAYED, 2014), adaptado

A cooperação através do compartilhamento de informações em uma rede multiagente pode ser explorada para resolver várias situações dentre as quais problemas de adaptação, aprendizado e otimização de forma descentralizada, inclusive para fins de aplicação em problemas de gerenciamento de recursos. Nesse contexto, considerando uma rede multiagente composta de N agentes, associa-se a cada agente k uma função de custo individual duplamente diferenciável e convexa $J_k(w)$ para atender ao objetivo de fornecer o único minimizador da função custo agregado (SAYED *et al.*, 2014). Essa configuração é representada na Figura 8, em que a variável w representa a variável incremental resultante da diferenciação da função custo J de cada agente. Nas situações em que os agentes precisam trabalhar cooperativamente para atingir um objetivo comum, os minimizadores dos custos individuais coincidem, representando um minimizador global que representa a solução ideal para o problema. Para isso, utiliza-se estratégias de otimização distribuída como estratégias incrementais, Consenso, Difusão e Difusão Exata.

Figura 8 – Configuração de Rede Multiagente para gerenciamento de recursos



Fonte: (SAYED, 2014), adaptado

3.5 Estratégias de Otimização Distribuída

3.5.1 Consenso

Para uma rede multiagente, a solução do gerenciamento de múltiplos recursos com custos individuais diferenciáveis $J - w$ envolve o somatório destes custos individuais conforme (3.1). O objetivo da rede de agentes é buscar o minimizador w^0 da função custo agregado $J^{glob}(w)$ e pode ser descrito na forma (3.2).

$$J^{glob}(w) = \sum_{k=1}^N J_k(w) \quad (3.1)$$

$$w^0 = \min J(w) \quad (3.2)$$

Em que:

- $J^{glob}(w)$: função custo agregado.
- $J(w)$: função convexa e duplamente diferenciável com relação a w .
- w : variável incremental determina a minimização de J a ser diferenciado no processo de otimização.

- w^0 : valor mínimo global.

Dentre as técnicas utilizadas em problemas de minimização de custos com as características de (3.2) está a utilização de algoritmos gradiente descendentes através de estratégias incrementais como disposto na forma em (3.3). A atualização do custo incremental $w_{k,i}$ do agente k , envolve a variável incremental $w_{k-1,i}$ recebida do agente vizinho na etapa de (3.3) denominada cooperação. A segunda parcela de (3.3) corresponde à descentralização em que a variável incremental do agente será atualizada utilizando sua própria aproximação do vetor gradiente. Sucessivas iterações levam à convergência de $w_{k,i}$ para w_0 , a rapidez dessa convergência é influenciada pelo tamanho do passo, nesse estudo denominado ganho de *feedback* (SAYED *et al.*, 2014).

$$w_{k,i} = w_{k-1,i} - \mu \nabla_{w^T} J(w_{k-1,i}), i \geq 0 \quad (3.3)$$

Em que:

- i : índice de iteração.
- w : variável incremental compartilhada pelos agentes da rede.
- μ : tamanho de passo.
- ∇_{w^T} : vetor gradiente da função a ser minimizada.

Baseando-se na ideia de estratégias incrementais e gradiente descente, constitui-se o Consenso. A cooperação é verificada através da combinação das iterações disponíveis nos vizinhos do agente conforme verificado na parcela de somatório de (3.4) em substituição à primeira parcela de (3.3), que usa apenas os dados do próprio agente. Trata-se do compartilhamento da variável ou custo incremental dos agentes l vizinhos do agente k . No Consenso, a descentralização é substituída pela da segunda parcela de (3.4), em que o gradiente da função a ser minimizada, utilizando o custo incremental do próprio agente k na iteração anterior $i - 1$, contribui para atualizar este valor que corresponderá a $w_{k,i}$.

$$w_{k,i} = \sum_{l \in N_k} a_{lk} w_{l,i-1} - \mu_k \nabla_w J_k(w_{k,i-1}) \quad (3.4)$$

Em que:

- $w_{k,i}$: variável incremental do agente k para a iteração i .
- a_{lk} : coeficiente de combinação entre os agentes l e k .
- N_k : conjunto de agentes vizinhos de k

- $w_{l,i-1}$: variável incremental do agente l na iteração $i - 1$.
- μ_k : tamanho de passo do agente k .
- $\nabla_w J_k(w_{k,i-1})$: gradiente da função a ser minimizada em função da variável incremental de k na iteração $i - 1$.

3.5.2 Revisão Bibliográfica: Consenso e Despacho Econômico de Microrredes

Muitos estudos fornecem soluções para o problema de despacho econômico ótimo usando abordagens de otimização centralizada que requerem uma entidade central que receba informações de todas as variáveis relevantes em todo o sistema. Essa abordagem, entretanto apresenta alguns desafios como os citados na Seção 3.3. Em contraste, os benefícios das abordagens de otimização distribuída incluem maior tolerância a falhas, maior velocidade de resposta, mais robustez e escalabilidade (YU *et al.*, 2020). Tais abordagens vêm ganhando grande visibilidade para o problema de despacho ótimo com destaque para otimização por Consenso.

Nos estudos que adotam a otimização por Consenso para despacho em MRs, cada recurso energético e cada carga controlável constituem um agente que tem a capacidade de se comunicar com um número limitado de agentes vizinhos, processar os dados coletados e regular sua potência de acordo com um intervalo limite previamente estabelecido (LOIA; VACCARO, 2013).

Em (WANG *et al.*, 2018), é introduzido um algoritmo de Consenso totalmente distribuído para resolver o problema de despacho em uma rede com agentes de geração despachável, no qual o *mismatch* local entre a demanda e a geração ativa é atribuído como variável de feedback. Diferentemente dos outros estudos relacionados, os ganhos de feedback atribuídos a estas variáveis são diferentes e variáveis no tempo.

Em (WANG *et al.*, 2019) é apresentado um despacho econômico ótimo de microrredes com agentes de geração despachável e de geração renovável baseado no algoritmo Consenso.

Em (YU *et al.*, 2020), aplica-se o Consenso para solucionar o problema de despacho econômico com efeito de atraso aleatório em uma MR representada através de um Sistema Multiagente de tempo contínuo, considerando o impacto de qualquer falha do agente no desempenho do sistema. Agentes de geração despachável são contemplados no estudo.

Em (ALI *et al.*, 2020), o Consenso é utilizado no despacho de uma MR para os modos ilhado e conectado. Os agentes contemplados no problema são: geração renovável,

geração despachável, sistema de armazenamento, carga crítica e carga não-crítica.

3.5.3 Difusão

Analisando as etapas de cooperação e descentralização da otimização por Consenso em (3.4), verifica-se que esses fatores são tratados de forma assimétrica quanto às variáveis incrementais adotadas em cada etapa. O termo de descentralização é a variável incremental do próprio agente k , $w_{k,i-1}$. A variável incremental da cooperação é diferente, envolvendo uma combinação convexa das variáveis incrementais $w_{l,i}$ dos demais agentes. Essa característica pode ser um problema quando a estratégia é usada para adaptação e aprendizado em redes. Isso ocorre porque a assimetria pode causar um crescimento instável no estado da rede. As estratégias de otimização por Difusão eliminam o problema da assimetria. (SAYED *et al.*, 2014).

Existem diversas estratégias de difusão, dentre elas, a estratégia *Adapt Then Combine* (ATC). Nessa estratégia, a primeira etapa consiste na Adaptação em que o agente k usa seu vetor gradiente aproximado para atualizar a variável incremental $w_{k,i-1}$ que usa uma variável intermediária através de informações compartilhadas pelos agentes vizinhos. A segunda etapa consiste em uma agregação em que o agente k combina as iterações intermediárias dos agentes vizinhos para obter sua iteração atualizada $w_{k,i}$. Todos os agentes da rede executam essas etapas que podem ser combinadas de forma resumida como uma única atualização conforme a equação (3.5). Os vetores gradientes dos agentes vizinhos estão sendo combinados pela atualização do ATC, sendo cada gradiente avaliado na respectiva iteração.

$$w_{k,i} = \sum_{l \in N_k} a_{lk} w_{l,i-1} - \sum_{l \in N_k} a_{lk} \mu_l \nabla_w * J_l(w_{l,i-1}) \quad (3.5)$$

Em que:

- $w_{k,i}$: variável incremental do agente k para a iteração i .
- a_{lk} : coeficiente de combinação entre os agentes l e k .
- N_k : conjunto de agentes vizinhos de k
- $w_{k,i-1}$: variável incremental do agente l na iteração $i - 1$.
- μ_k : tamanho de passo do agente k .
- $\nabla_w J_k(w_{k,i-1})$: gradiente da função a ser minimizada em função da variável incremental de k na iteração $i - 1$.

3.5.4 Revisão Bibliográfica: Difusão e Despacho Econômico de Microrredes

No âmbito de despacho econômico de Microrredes, verificou-se a aplicação da Difusão em (AZEVEDO *et al.*, 2017). Neste trabalho é proposto o controle de uma MR baseado em multiagente através da estratégia de Difusão. Verifica-se um controle hierárquico em 2 níveis. No nível inferior, implementa-se um esquema de *droop* adaptativo para o controle de frequência. No nível superior, a Difusão é adotada em uma rede multiagente para o gerenciamento de uma MR. Os agentes contemplados no problemas são: geração renovável, geração despachável, carga, bateria e rede distribuição. Estes agentes são implementados na plataforma *Java Agent Development Framework* (JADE).

3.5.5 Difusão Exata

Em (YUAN *et al.*, 2018) foi desenvolvido um algoritmo distribuído a partir da estratégia de Difusão, denominado Difusão Exata. Esse algoritmo garante a convergência exata apontando uma maior faixa de estabilidade e desempenho aprimorado. Além disso, como grande diferencial desse método de otimização, tem-se o funcionamento e convergência para uma maior classe de matrizes localmente balanceadas em substituição aos outros métodos que requerem matrizes duplamente estocásticas (YUAN *et al.*, 2018).

A estrutura de difusão exata é bastante próxima da estrutura de difusão padrão, havendo uma etapa extra de correção entre as etapas usuais de adaptação e combinação da Difusão. Conforme (YUAN *et al.*, 2018), a Difusão Exata tem uma faixa de estabilidade de alcance mais ampla do que outros métodos de otimização distribuída, ou seja, haverá uma gama mais ampla de tamanhos de passo que mantêm a difusão exata estável. Além disso, esse método possui propriedade de convergência para a classe de matrizes de peso localmente balanceadas e não apenas matrizes duplamente estocásticas simétricas, incluindo uma gama de matrizes estocásticas à esquerda amplamente utilizadas, a saber: *Hasting Rules*, *Averaging rule* e *Relative-degree rule*. Na Figura 9 é ilustrada a relação entre as classes de matrizes duplamente estocásticas, balanceadas estocásticas à esquerda e estocásticas à esquerda. As equações para os coeficientes a_{lk} de combinação entre dois agentes l e k a partir das matrizes *Hasting Rules*, *Averaging rule* e *Relative-degree rule* são apresentadas nas equações (3.6), (3.7) e (3.8). O somatório dos coeficientes de cada coluna de uma matriz estocástica à esquerda deve ser 1 ($A^T \mathbf{1} = \mathbf{1}$). Para matrizes duplamente estocásticas, os somatório de linhas e colunas deve ser 1.

$$a_{lk} = \begin{cases} \frac{\mu_k/q_k}{\max[n_k\mu_k/q_k, n_l\mu_l/q_l]}, l \in \Omega_k/k \\ 1 - \sum_{j \in \Omega_k} w_{jk}, l = k \\ 0, l \notin \Omega_k \end{cases} \quad (3.6)$$

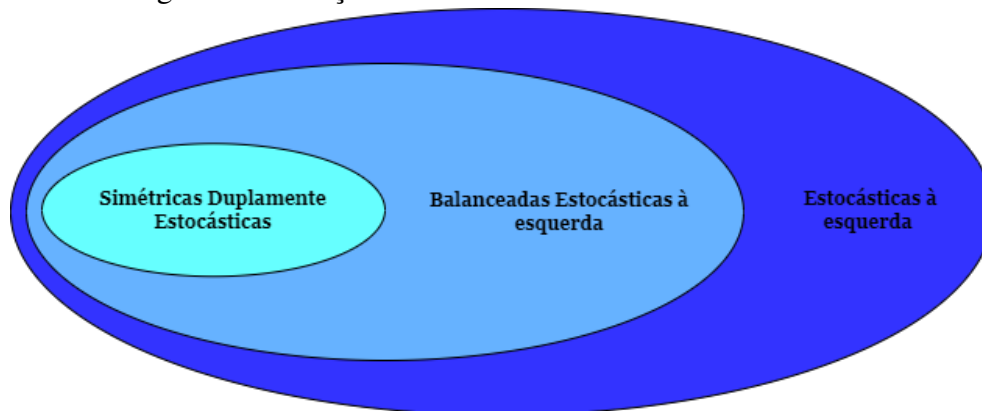
$$a_{lk} = \begin{cases} 1/n_k, l \in \Omega_k \\ 0, l \notin \Omega_k \end{cases} \quad (3.7)$$

$$a_{lk} = \begin{cases} \frac{n_l}{\sum_{m \in \Omega_k} n_m}, l \in \Omega_k \\ 0, l \notin \Omega_k \end{cases} \quad (3.8)$$

Em que:

- a_{lk} : combinação de combinação entre os agentes l e k .
- Ω_k : conjunto de vizinhos do agente k .
- n_k e n_l : número de vizinhos dos agentes k e l .
- μ_k e μ_l : tamanho de passo dos agentes k e l .
- $w_{l,k}$: elementos das matrizes de peso.

Figura 9 – Relação entre as Classes de Matrizes



Fonte: Própria da Autora

Na etapa de correção, a variável intermediária $\psi_{k,i}$ é corrigida, subtraindo-se dela a diferença entre $w_{k,i-1}$ e $\psi_{k,i-1}$ da iteração anterior. O processo de adaptação, correção e combinação está representado nas equações (3.9), (3.10) e (3.11), respectivamente.

$$\psi_{k,i} = w_{k,i-1} - \mu_k \nabla J_k(w_{k,i-1}) \quad (3.9)$$

$$\phi_{k,i} = \psi_{k,i} + w_{k,i-1} - \psi_{k,i-1} \quad (3.10)$$

$$w_{k,i} = \sum_{l \in N_k} \bar{a}_{lk} \phi_{l,i} \quad (3.11)$$

Em que:

- $\psi_{k,i}$: variável intermediária do agente k na iteração i .
- $\phi_{k,i}$: variável de correção do agente k na iteração i
- $w_{k,i}$: variável incremental do agente k na iteração i .

3.5.6 Revisão Bibliográfica: Difusão Exata e Despacho Econômico de Microrredes

A estratégia de Difusão Exata, desenvolvida em (YUAN *et al.*, 2018), foi empregada para solução do despacho ótimo de MRs em (HE *et al.*, 2019). O estudo envolveu a modelagem de agentes de geração renovável, geração despachável, carga flexível e bateria. Como diferenciais do estudo de (HE *et al.*, 2019), destacou-se a adoção de um método de otimização até então não empregado ao problema de despacho em microrredes e são simuladas situações de ocorrência de falha de comunicação e "*Plug and Play*", demonstrando a estabilidade e flexibilidade do algoritmo.

3.6 Contribuições e Principais fontes

Muitos estudos fornecem soluções para o problema de despacho econômico ótimo usando abordagens de otimização centralizada que requerem uma entidade central que receba informações de todas as variáveis relevantes em todo o sistema. Essa abordagem, entretanto apresenta alguns desafios como os citados na Seção 3.3, com destaque para a incapacidade dos agentes de contribuir para o processo de tomada de decisão do sistema, sendo meros implementadores de decisões tomadas em um nível superior. Em contraste, os benefícios das abordagens de otimização distribuída incluem a interação entre agentes quando se faz necessário compartilhamento de recursos, maior tolerância a falhas, maior velocidade de resposta, mais robustez e escalabilidade (YU *et al.*, 2020). Além das abordagens distribuídas destacadas neste estudo, outras abordagens verificadas para a solução do gerenciamento de recursos de uma MR podem ser citadas como o método do Gradiente Distribuído (ZHANG *et al.*, 2016), (XU *et al.*,

2013) e o método dos Multiplicadores de Direção Alternada (MA *et al.*, 2016). Tais abordagens vêm ganhando grande visibilidade para o problema de despacho ótimo. Verifica-se, assim, a necessidade de uma análise comparativa dentre os métodos distribuídos, buscando as vantagens e benefícios de cada um deles a fim de determinar o método mais favorável no contexto de despacho em MRs.

Além dos diferentes métodos de otimização utilizados para resolver o problema de despacho econômico, outra característica distintiva que diferencia os trabalhos de pesquisa é a modelagem de custos dos elementos dos recursos da microrrede, como geração renovável variável, geração despachável, dispositivos de carga e armazenamento. Modelos completos de componentes de microrredes retirados de diferentes artigos da literatura foram adotados neste estudo.

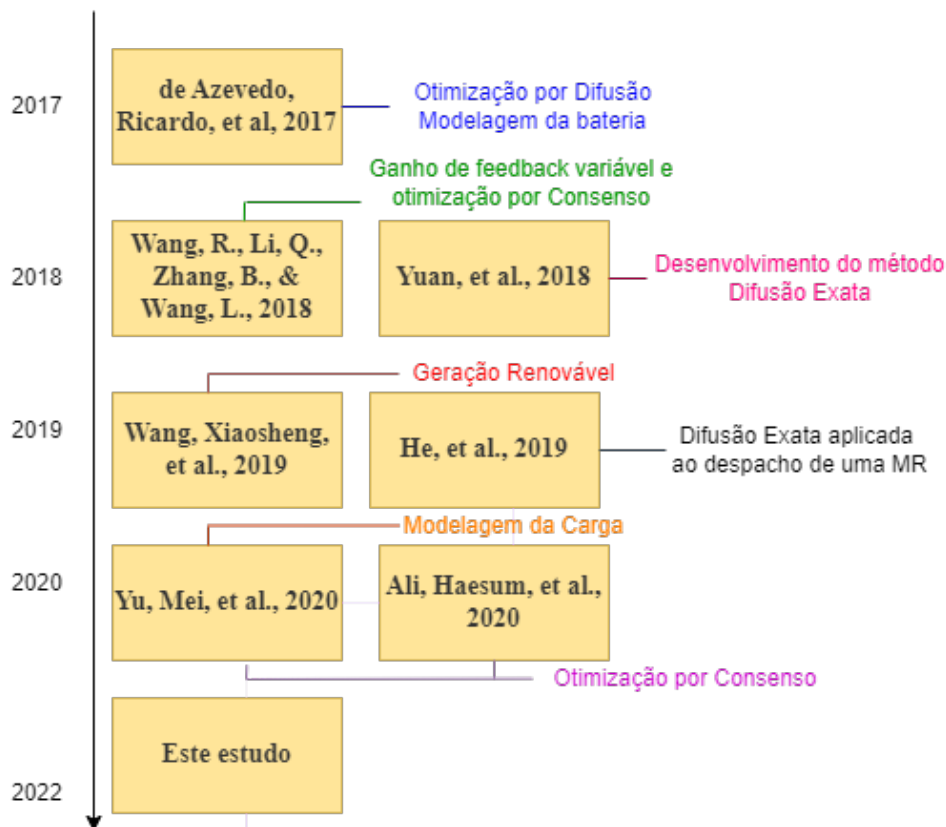
A linha do tempo mostrada na Figura 10 apresenta os principais artigos usados no desenvolvimento dos modelos de despacho econômico ótimo de MRs aplicados nesta dissertação. O modelo desenvolvido em (AZEVEDO *et al.*, 2017) foi adotado na dissertação como base para aplicação do método de Difusão. O estudo desenvolvido em (YUAN *et al.*, 2018) e (HE *et al.*, 2019) foi adotado como base para aplicação do método de Difusão Exata. O método de Consenso foi baseado em (WANG *et al.*, 2019). Os autores em (WANG *et al.*, 2018) adotaram um tamanho de passo variável, denominado ganho de feedback neste trabalho, para cada recurso energético para melhorar a eficiência do despacho ótimo por Consenso, tendo sido apontado como diferencial principal do estudo. Essa estratégia foi adotada na dissertação, sendo o ganho de feedback calculado através de AG. Além disso, a estratégia foi estendida aos métodos de Difusão e Difusão Exata. Quanto aos recursos energéticos, neste estudo, os métodos de otimização distribuída são aplicados para o gerenciamento de uma MR com agentes despacháveis e não despacháveis, além de cargas flexíveis. O modelo para geração renovável foi baseado em (WANG *et al.*, 2019). Um modelo de resposta a demanda que lida com redução de carga não crítica e aplicado com base em (YUAN *et al.*, 2018). O modelo do sistema de armazenamento é baseado em (AZEVEDO *et al.*, 2017). O desenvolvimento de cada modelo, as vantagens dos métodos e o uso de diferentes matrizes de peso foram consideradas e testadas neste estudo.

Neste trabalho, os métodos de otimização distribuída foram comparados em termos de esforço computacional considerando número de iterações até a convergência, número de operações efetuadas a cada iteração e complexidade destas operações. Além disso, os métodos foram comparados quanto à velocidade de convergência e a privacidade do método. Essa análise

busca determinar o método mais eficiente em termos de esforço computacional e velocidade de convergência, bem como a compatibilidade dos resultados obtidos. Além disso, algumas estratégias foram adotadas a fim de tornar os métodos ainda mais favoráveis e robustos. As principais contribuições deste estudo são elencadas nos tópicos seguintes:

- Comparação de três métodos de otimização distribuída em aspectos de esforço computacional, velocidade de convergência e privacidade da informação;
- Extensão da utilização de ganho de *feedback* variável aos métodos de Difusão e Difusão Exata;
- Análise do desempenho da otimização por Difusão exata quando da utilização de outras matrizes de peso além da obtida através da Regra de Metropolis.

Figura 10 – Linha do Tempo de Referências



Fonte: Própria da autora

3.7 Considerações Finais

Este capítulo apresentou alguns métodos verificados na literatura para a solução do despacho ótimo em microrredes. Os métodos de otimização distribuída explorados neste estudo

foram detalhados, apresentando suas características e peculiaridades. A revisão bibliográfica apontou como diferentes métodos foram aplicados ao problema de gerenciamento dos recursos de uma microrrede, apontando quais as contribuições extraídas de cada um desses estudos para, então, abordar as contribuições deste trabalho.

4 FORMULAÇÃO DO PROBLEMA E MODELAGEM DOS AGENTES DA MICRORREDE

4.1 Introdução

As soluções do despacho ótimo de MR através de métodos de otimização distribuída envolve a modelagem dos REDs que constituem agentes. Nesse estudo os recursos considerados são geração renovável, geração despachável, bateria, cargas e rede. Neste capítulo serão abordadas as modelagens de custo adotadas, bem como a aplicação dos métodos de otimização distribuída ao problema de despacho econômico de uma microrrede.

4.2 Modelagem dos Agentes

4.2.1 Agente Geração Despachável

Fontes convencionais de geração de energia como geradores a diesel são considerados agentes despacháveis e, para fins de despacho ótimo, o custo da geração é modelado comumente por uma função quadrática da potência a ser disponibilizadas cujos coeficientes de custo são α , β e γ como em (4.1). O custo incremental é obtido através de (4.2), correspondendo à derivada parcial do custo do agente com relação à potência. O agente geração despachável é sujeito a restrições técnicas de potência disponível representadas em (4.3). O valor do custo incremental é compartilhado entre agentes vizinhos no processo de otimização.

$$C_{DG} = \alpha P_{DG}^2 + \beta P_{DG} + \gamma \quad (4.1)$$

$$\frac{\partial C_{DG}}{\partial P_{DG}} \doteq 2\alpha P_{DG} + \beta \quad (4.2)$$

$$P_{DG}^{min} < P_{DG} < P_{DG}^{max} \quad (4.3)$$

Em que:

- C_{DG} : custo agente geração despachável.
- $\frac{\partial C_{DG}}{\partial P_{DG}}$: custo incremental agente geração despachável.
- P_{DG} : potência a ser disponibilizada pelo agente geração despachável.

- P_{DG}^{min} : potência mínima disponível pelo agente geração despachável.
- P_{DG}^{max} : potência máxima disponível pelo agente geração despachável.

4.2.2 Agente Geração Renovável

As fontes de geração não despacháveis, notadamente a eólica e a solar, são recursos inerentes aos novos modelos de redes elétricas ativas. Comumente, em problemas de despacho ótimo, o custo atribuído a essas fontes é nulo. Algumas referências adotam custos de manutenção e perdas para fontes renováveis, entretanto, nota-se que estes custos são pouco significativos. Um outro fator importante é a utilização de modelos de previsão da geração renovável para a previsão de despacho dos recursos de uma microrrede. Neste estudo, atribuiu-se custo nulo às fontes de geração despachável. Assim, prioriza-se a utilização da geração renovável no atendimento da carga prevista para Microrrede.

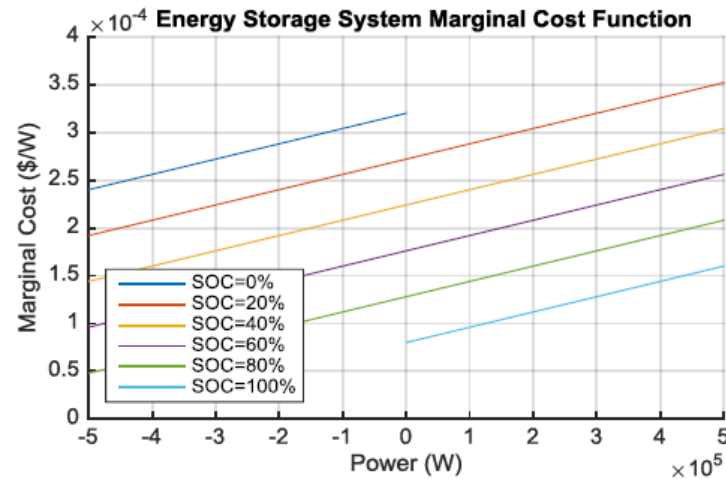
A potência prevista para a geração renovável é considerada uma carga negativa, sendo usada para determinação da demanda líquida conforme proposto em (ALI *et al.*, 2020). Os valores adotados neste estudo foram obtidos a partir de uma previsão com horizonte temporal de 1 hora obtida em (ALI *et al.*, 2020) e serão especificados no Capítulo 5. Utiliza-se a informação da potência prevista proveniente de fontes renováveis nas variáveis de inicialização. Durante o processo de otimização, esse agente participa do compartilhamento de informações com os demais agentes. Entretanto, diferente dos demais agentes, a potência deste agente não é atualizada a cada iteração, permanecendo em zero, pois seus efeitos já foram considerados no início do problema.

4.2.3 Agente Bateria

Os agentes que compõem o sistema de armazenamento da microrrede são modelados como baterias com controle bidirecional, com capacidade de carga e descarga. O agente bateria é bidirecional e deve carregar idealmente quando o custo incremental for baixo e ao contrário, suprir a carga quando o custo incremental for alto. Assim, adotou-se a equação (4.4) proposta em (AZEVEDO *et al.*, 2017) para representar o custo C_B deste agente como função do estado de carregamento (SOC) e da capacidade máxima (P_{max}). O custo incremental é apresentado em (4.5) é proporcional à potência fornecida ou absorvida pela bateria, que pode ser negativa ou positiva, e, inversamente proporcional ao estado de carregamento, o que implica que o custo incremental será menor à medida que o SOC se aproximar de 100% conforme ilustrado na Figura 11. Nesta

Figura, observa-se que para SOC=0% a potência é negativa (somente carga) e para SOC=100% a potência pode ser entregue (descarregada). Os valores máximo e mínimo de potência do agente, que correspondem ao máximo de potência de descarregamento e carregamento, variam conforme o SOC de acordo com (4.6).

Figura 11 – Relação entre o SOC e Custo Incremental



Fonte: (AZEVEDO *et al.*, 2017)

$$C_B = \beta(P_B + 3P_B^{max}(1 - SOC)) + \alpha(P_B + 3P_B^{max}(1 - SOC))^2 + \gamma \quad (4.4)$$

$$\frac{\partial C_B}{\partial P_B} = \beta + \alpha(2P_B + 6P_B^{max}(1 - SOC)) \quad (4.5)$$

$$(SOC - 1)P_B^{max} \leq P_B \leq P_B^{max} SOC \quad (4.6)$$

Em que:

- C_B : custo agente bateria.
- $\frac{\partial C_B}{\partial P_B}$: custo incremental agente bateria.
- P_B : potência a ser disponibilizada pelo agente bateria.
- SOC : estado de carregamento agente bateria.
- P_B^{max} : potência máxima agente bateria quando totalmente carregado.

4.2.4 Agente Carga

Neste estudo foram adotados dois modelos para o agente carga de acordo com o modo de operação da microrrede. Para o modo ilhado, foi considerada a possibilidade de

necessidade de corte de carga, havendo os agentes carga crítica e carga não crítica. Para o modo conectado, há um agente carga que participa do processo de compartilhamento de informações com os demais agentes sem contudo necessitar de corte de carga.

4.2.4.1 Agentes Carga no Modo Ilhado

Para situações em que uma microrrede opera no modo ilhado, é de suma importância o controle do equilíbrio entre oferta e demanda de energia através do controle da demanda nos casos em que não é possível supri-la totalmente. Para situações de operação em modo ilhado, constituiu-se, então, dois agentes para a modelagem da carga, dividindo-a em crítica e não crítica. A função utilidade U que modela esses agentes deve representar o grau de satisfação do cliente em consumir determinado nível de potência. Trata-se de uma função côncava não decrescente, representando o interesse em consumir mais energia conforme proposto na equação (4.7) e ilustrado na Figura 12, que expressa o grau de satisfação do cliente em consumir mais uma unidade de carga. A função utilidade também deve ser constituída de forma que a derivada do benefício incremental seja uma função decrescente e o nível de satisfação gradualmente fique saturado no ponto em que o valor da função utilidade é máximo, conforme demonstrado em (4.8). Os valores adotados neste estudo foram obtidos a partir de uma previsão com horizonte temporal de 1 hora obtida em (ALI *et al.*, 2020) e serão especificados no Capítulo 5.

$$\frac{\partial U_C}{\partial P_C} \geq 0 \quad (4.7)$$


$$\frac{\partial^2 U_C}{\partial^2 P_C} < 0 \quad (4.8)$$

Para atender aos critérios propostos de modelagem, adotou-se a função utilidade proposta em (ALI *et al.*, 2020), cuja equação é (4.9). A prioridade de atendimento entre as cargas críticas e flexíveis se dá através dos coeficientes de benefício pré-determinados w e v . Assim, as cargas flexíveis são passíveis de corte, nos casos em que as fontes disponíveis não são suficientes para abastecer a carga completa. O benefício incremental a ser compartilhado pelos agentes é representado em (4.10).

$$\begin{cases} U = w \cdot P_C - \left(\frac{v}{2}\right) \cdot P_C^2, 0 \leq P_C \leq \frac{w}{v} \\ U = \frac{w^2}{v}, P_C > \frac{w}{v} \end{cases} \quad (4.9)$$

$$\frac{\partial U_C}{\partial P_C} = w - v \cdot P_C \quad (4.10)$$

Figura 12 – Função Utilidade



Fonte: (AGUIAR, 2008)

Em que:

- U : benefício em consumir determinada quantidade de potência.
- $\frac{\partial U_C}{\partial P_C}$: benefício incremental.
- P_C : potência a ser consumida.

4.2.4.2 Agentes Carga no Modo Conectado

Para o modo conectado, informação de carga prevista é necessária para as variáveis de inicialização, através do cálculo da demanda líquida. Durante a otimização, o agente correspondente a este recurso contribui para convergência através do compartilhamento e atualização de informações de custo incremental e mismatch de potência de forma semelhante aos demais agentes. No entanto, o agente carga não atualiza a potência, que permanece zero a cada iteração, pois sua contribuição já foi considerada na variável de entrada.

4.2.5 Agente Rede

O agente de rede está ativo apenas quando a MR está operando no modo conectado à rede e é responsável por controlar a transação de energia entre a rede elétrica e a MR. Além disso, este agente é responsável por compartilhar as informações de preços de tarifa para seus agentes vizinhos. O preço de mercado oferecido pela concessionária é modelado como uma função linear, com custo incremental constante, conforme descrito em (4.11) e (4.12), respectivamente. A modelagem do agente rede possibilita a compra de energia pela MR ($P_r > 0$) e venda de energia para rede externa ($P_r < 0$), de forma que C_r representa o seu custo ou lucro. Durante o processo

de otimização o agente rede permanece compartilhando a informação da tarifa para os demais agentes a cada iteração.

$$C_r = \rho \cdot P_r \quad (4.11)$$

$$\frac{\partial C_r}{\partial P_r} = \rho \quad (4.12)$$

Em que:

- C_r : custo ou lucro agente rede
- $\frac{\partial C_r}{\partial P_r}$: custo incremental agente rede.
- ρ : preço de mercado oferecido pela concessionária em unidade monetária por unidade de potência.

4.3 Modelagem do Despacho Econômico em Microrredes

4.3.1 Formulação do Problema

4.3.1.1 Função Objetivo para o Modo Ilhado

O objetivo do problema de despacho ótimo de uma microrrede quando operando em modo ilhado consiste em minimizar o custo total de operação dos REDs. As restrições do problema envolvem o gerenciamento da carga de modo a garantir o balanço de potência e, além disso, os limites de potência dos agentes devem ser atendidos. A função objetivo é, então, representada matematicamente através das equações (4.13) e (4.14), cujos objetivos são minimizar, respectivamente, o somatório do custo individual de cada agente i em função da potência e minimizar a quantidade de carga cortada. As equações (4.15) e (4.16) representam as restrições desse problema, de forma que haja o equilíbrio entre a energia demandada e ofertada além da observância aos limites individuais de potência de cada agente e da quantidade de carga cortada.

$$\min \sum_{i=1}^n C_i(P_i) \quad (4.13)$$

$$\min P_{corte} \quad (4.14)$$

$$P_{DG} + P_B + P_{corte} = D \quad (4.15)$$

$$P_i^{min} < P_i < P_i^{max} \quad (4.16)$$

Em que:

- $C_i(P_i)$: custo de cada agente i associado à potência P_i .
- P_{corte} : potência de carga sujeita a corte.
- P_{DG} : potência geração despachável.
- P_B : potência bateria.
- D : demanda líquida considerando a contribuição da geração renovável.
- P_i^{min} : potência mínima agente i .
- P_i^{max} : potência máxima agente i .

4.3.1.2 Função Objetivo para o Modo Conectado

Para o modo conectado, em que não há necessidade de corte de carga, a função objetivo é representada matematicamente através de (4.17), sujeita à restrição de balanço de potência conforme (4.18) e aos limites individuais de potência de cada agente conforme (4.16).

$$\min \sum_{i=1}^n C_i(P_i) \quad (4.17)$$

$$P_{DG} + P_B + P_r = D \quad (4.18)$$

- $C_i(P_i)$: custo de cada agente i associado à potência P_i .
- P_{DG} : potência geração despachável.
- P_B : potência bateria.
- P_r : potência vendida ou comprada pela rede
- D : demanda líquida considerando a contribuição da geração renovável.

4.3.2 Operação Ótima

Neste estudo, propõe-se estratégias para operação ótima de uma MR, tanto para operação em modo conectado à rede quanto em modo ilhado. Para o modo conectado, o método proposto pode determinar de forma otimizada a troca de energia com a rede elétrica. Além disso, para operação em modo ilhado, o método proposto pode determinar a potência ótima alocada às fontes e às cargas com base em suas prioridades.

Uma MR é caracterizada por proporcionar confiabilidade de serviço para cargas críticas durante interrupções e contingências da rede de distribuição externa. Quando opera em modo ilhado, a MR não pode transacionar energia com a rede elétrica. Portanto, nesse modo, durante os intervalos de pico de carga, o corte de carga pode ocorrer devido à capacidade limitada de geração e armazenamento. Nesse caso, é necessário fornecer confiabilidade de serviço para carga crítica. Além disso, o carregamento da bateria só deve ser considerado quando não houver queda de carga crítica na rede da MR. Os agentes considerados para esse modo são: carga crítica e não críticas, geração despachável e renovável e bateria. Para operação em modo ilhado, propõe-se a minimização de custos quando as fontes são suficientes para suprir a carga ou a maximização do bem-estar e, conseqüentemente, do benefício incremental nos casos em que há necessidade de corte de carga. Esses agentes formam uma rede de comunicação em anel demonstrada na Figura 13. A operação ótima da MR ilhada, descrita em (4.20), é um ponto em que o custo incremental de cada um dos 5 agentes converge para λ^* , que é o multiplicador de Lagrange (TANG *et al.*, 2018), associado à função de Lagrange, que é construída usando a função objetivo e a restrição de balanço de potência conforme (4.19). Tomando as derivadas parciais e o multiplicador de Lagrange desta equação, a condição ótima da função objetivo sob a restrição de balanço de potência será obtida.

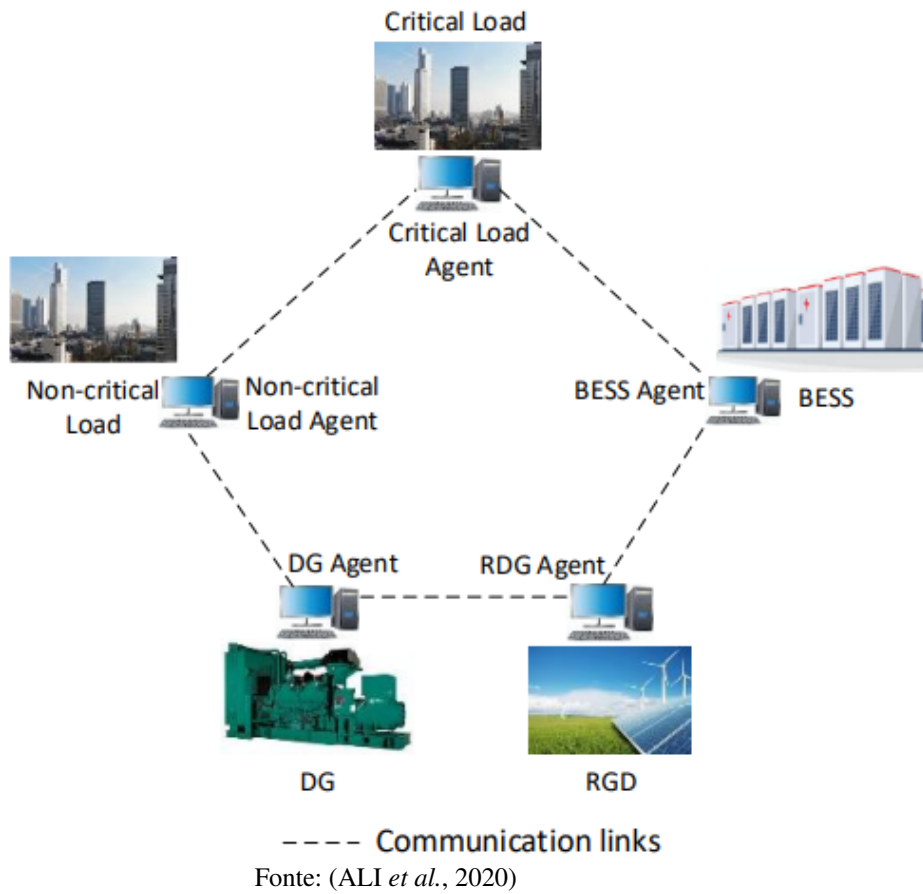
$$L(P_1, P_2, \dots, P_N, \lambda) = \sum_{i=1}^N C_i(P_i) + \lambda(P_C - P_{DG} - P_{ren} - P_B) \quad (4.19)$$

$$\frac{\partial C_1}{\partial P_1} = \frac{\partial C_2}{\partial P_2} = \frac{\partial C_3}{\partial P_3} = \frac{\partial C_4}{\partial P_4} = \frac{\partial C_5}{\partial P_5} = \lambda \quad (4.20)$$

Em que:

- $L(P_1, P_2, \dots, P_N, \lambda)$: função de Lagrange.
- λ : multiplicador de Lagrange.

Figura 13 – Rede de Agentes no Modo Ilhado



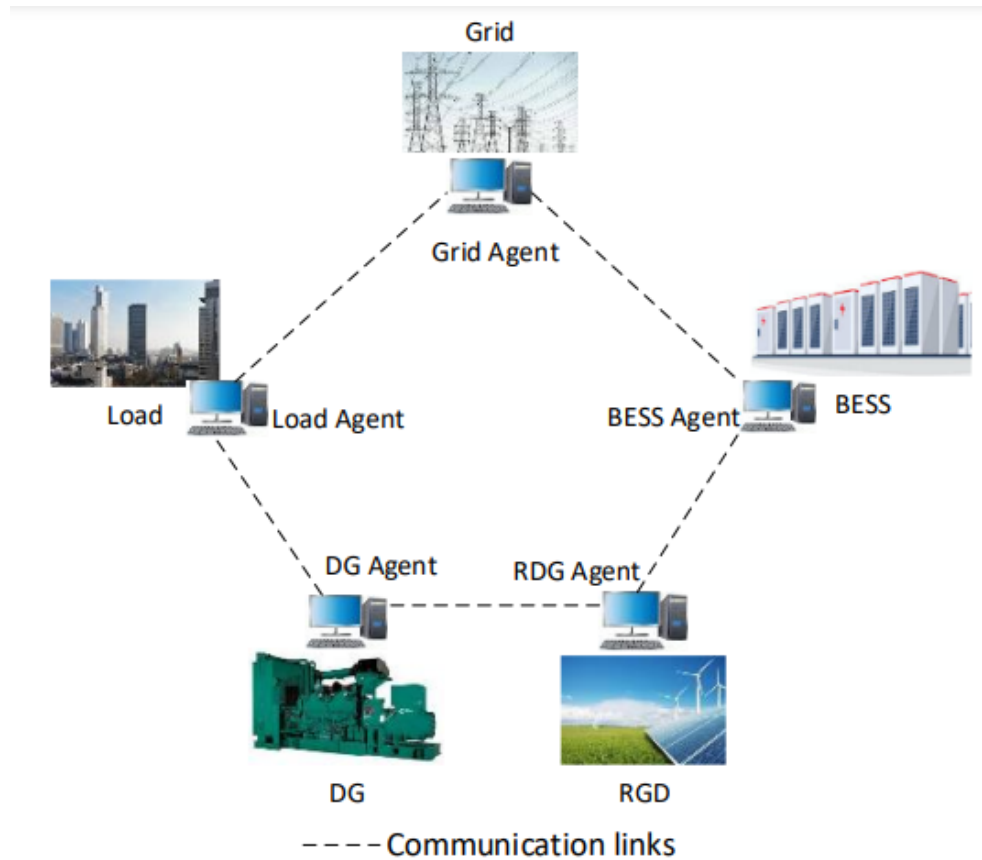
Durante o modo conectado à rede, o principal objetivo da operação é minimizar o custo de operação da microrrede, mantendo o equilíbrio de energia na rede. Como a MR está operando no modo conectado à rede, a energia pode ser comprada ou vendida à concessionária a qual está conectada para manter o equilíbrio de energia e maximizar o lucro, respectivamente. O método do multiplicador de Lagrange estabelece que a operação ótima da microrrede conectada à rede é um ponto onde o custo incremental de cada agente despachável converge para o preço de mercado ρ conforme verificado na Equação (4.21) (HE *et al.*, 2019). Na Figura 14 é apresentada a rede com configuração em anel de agentes para o modo conectado.

$$\frac{\partial C_1}{\partial P_1} = \frac{\partial C_2}{\partial P_2} = \frac{\partial C_3}{\partial P_3} = \frac{\partial C_4}{\partial P_4} = \frac{\partial C_5}{\partial P_5} = \rho \quad (4.21)$$

4.3.3 Consenso aplicado ao Despacho Ótimo em Microrredes

A otimização por Consenso apresenta características vantajosas à aplicação no problema de despacho em microrredes, tais quais a rápida convergência, a quantidade reduzida

Figura 14 – Rede de Agentes no Modo Conectado



Fonte: (ALI *et al.*, 2020)

de informações necessárias e a adaptabilidade a mudanças na configuração do sistema, como adição ou remoção de agentes através da atualização da matriz de comunicação.

No algoritmo de Consenso de Custo Incremental, cada agente mantém a variável de consenso atualizada, o custo incremental, através da troca regular de informação com os agentes vizinhos. Essa informação é utilizada para ajuste dos pontos de operação dos agentes e respectivas potências. O processo se repete até que se atinja a convergência de custo incremental de todos os agentes em um cenário de equilíbrio entre oferta e demanda.

O compartilhamento de informações entre os agentes da microrrede é representado a partir da Teoria dos Grafos. A modelagem da matriz de adjacências é obtida a partir do critério de Metropolis, obtendo-se a matriz de pesos A , cujos coeficientes a_{ij} são obtidos a partir da equação (4.22). Essa matriz de pesos obtida pela regra de Metropolis garante estabilidade ao algoritmo de Consenso.

$$a_{ij} = \begin{cases} \frac{1}{\max(n_i, n_j)} & , i \in N_j \\ 1 - \sum_{i \in N_j} a_{ij} & , i = j \end{cases} \quad (4.22)$$

Em que:

- a_{ij} : coeficiente de peso para comunicação entre os agentes.
- N_j : agentes vizinhos do agente j .

O algoritmo de Consenso aplicado ao despacho ótimo em Microrredes envolve a contínua atualização do custo incremental λ_i^{k+1} e potência dos agentes i a cada iteração k até a convergência. Essa variável representa as derivadas parciais do custo de cada agente. Através de (4.23) obtém-se o custo incremental atualizado por iteração. Nesta equação, ε representa o ganho de *feedback*, ou tamanho de passo, aplicado ao incremento de potência ΔP_i^k do agente na iteração. Esse valor é calculado conforme (4.24).

$$\lambda_i^{k+1} = \sum_{j \in N_i} a_{ij} \lambda_j^k + \varepsilon \Delta P_i^k. \quad (4.23)$$

$$\Delta P_i^{k+1} = \sum_{j \in N_i} a_{ij} \Delta P_j^k - (P_i^{k+1} - P_i^k) \quad (4.24)$$

Em que:

- λ_i^{k+1} : custo incremental na iteração $k + 1$.
- a_{ij} : coeficiente de peso entre os agentes i e j .
- ε ganho de *feedback* aplicado ao *mismatch* de potência.
- ΔP_i^{k+1} : desbalanço de potência da iteração $k + 1$.
- P_i^{k+1} : potência do agente i na iteração $k + 1$.

A partir da atualização do valor de custo incremental do agente, as potências correspondentes são atualizados conforme (4.25). Esse processo se repete até que o custo incremental de todos os agentes seja equivalente. O agente de geração renovável, que possui custo zero, não atualiza sua potência que permanece zero a cada iteração, sendo sua contribuição anterior à execução do Consenso para os modos ilhado e conectado. No caso do modo conectado, o agente carga também não atualiza sua potência que permanece zero a cada iteração, pois o valor da carga prevista é utilizado no cálculo da demanda líquida, que é uma variável inicial.

$$\left\{ \begin{array}{l} P_{DG} = \frac{\lambda_i - \beta_{DG}}{2\alpha_{DG}} \\ P_{Load} = -\frac{\lambda_i - w}{u} \\ P_B = \frac{1}{2} \left(\frac{\lambda_i - \beta_B}{\alpha_B} + 6P_B^{max}(SOC - 1) \right) \end{array} \right. \quad (4.25)$$

Em que:

- P_{DG} : potência da geração despachável atualizada a partir do custo incremental.
- P_{Load} : potência da carga atualizada a partir do custo incremental.
- P_B : potência da bateria atualizada a partir do custo incremental.
- λ_i : custo incremental da iteração i .
- $\beta_{DG}, \alpha_{DG}, w, v, \beta_B, \beta_B$: coeficientes de custo dos agentes geração despachável, carga e bateria, respectivamente.
- P_B^{max} : potência máxima do agente bateria.
- SOC : estado de carregamento.

A solução ótima e a convergência do problema de despacho econômico dependem dos valores iniciais do custo incremental, potência e incremento de potência de cada agente e foram estabelecidos conforme recomendado em (ALI *et al.*, 2020) . Em (4.26) e (4.27) são apresentados os valores de inicialização para os modos ilhado e conectado, respectivamente.

$$\left\{ \begin{array}{l} \lambda_i^0 = 2\alpha_i P_i^0 + \beta_i \\ P_i^0 = 0 \\ \Delta P_i^0 = \frac{R}{N} \end{array} \right. \quad (4.26)$$

$$\left\{ \begin{array}{l} \lambda_i^0 = 2\alpha_i P_i^0 + \beta_i \\ P_i^0 = \text{qualquer valor} \\ \Delta P_i^0 = \frac{D}{N} \end{array} \right. \quad (4.27)$$

Em que:

- λ_i^0 : custo incremental do agente i na iteração inicial.
- α_i, β_i : coeficientes de custo do agente i .
- P_i^0 : potência inicial dos agentes i .
- ΔP_i^0 : incremento de potência inicial do agente i .
- R : potência renovável prevista.
- D : demanda líquida prevista.
- N : número de agentes.

4.3.4 Difusão aplicado ao Despacho Ótimo em Microrredes

O algoritmo de Difusão *Adapt-Then-Combine*, diferentemente do Consenso, utiliza um termo gradiente como uma etapa intermediária, que é disseminado aos agentes vizinhos

(AZEVEDO *et al.*, 2017). Isso contribui para que o processo de compartilhamento de informação entre os agentes seja mais rápido.

A Difusão ATC envolve duas etapas, Adaptação e Combinação. Na Adaptação cada agente recebe informação de seus adjacentes e calcula o gradiente da função objetivo, que garante o equilíbrio de potência entre os agentes conforme (HE *et al.*, 2019). A partir desse processo é calculada uma variável intermediária. Na etapa Combinação, a integração das variáveis intermediárias de todos os agentes irá constituir a atualização do custo incremental.

O cálculo do gradiente da função objetivo J_i do problema, a variável intermediária φ_i^k e a atualização do custo incremental são apresentados em (4.28), (4.29) e (4.30), respectivamente. O valor inicial da variável intermediária φ_i^0 é igual ao valor inicial do custo incremental λ_i^0 .

$$-\nabla_{\lambda} J_i(\lambda_i^{k-1}) = \sum_{i=1}^N P_i^{k-1} - \sum_{i=1}^N P_{ren} \quad (4.28)$$

$$\varphi_i^k = \lambda_i^{k-1} - \varepsilon \nabla_{\lambda} J_i^{k-1} \quad (4.29)$$

$$\lambda_i^k = \sum_{j \in N_i} a_{ij} \varphi_j^k \quad (4.30)$$

Em que:

- $\nabla_{\lambda} J_i(\lambda_i^{k-1})$: termo gradiente da função objetivo em função do custo incremental.
- P_i^{k-1} : potência do agente i na iteração $k - 1$.
- P_{ren} : potência renovável disponível.
- φ_i^k : variável intermediária do agente i na iteração k .
- ε : ganho de feedback.
- λ_i^k : custo incremental do agente i na iteração k .

A matriz de pesos que modela a rede de comunicação é a mesma utilizada na otimização por Consenso, pois para convergência da Difusão a Matriz de Adjacências deve ser duplamente estocástica

4.3.5 Difusão Exata para o Despacho Ótimo em Microrredes

Para superar a limitação da condição de matriz duplamente estocástica exigida pelos métodos de Consenso e Difusão, o que significa que os requisitos de topologia e protocolo de

comunicação entre os agentes são mais rigorosos, em (HE *et al.*, 2019) é adotado o algoritmo de Difusão Exata de forma modificada. Trata-se de um algoritmo de otimização distribuído com convergência exata garantida pela remoção de viés em implementações de Difusão ATC padrão através da adição de mais uma etapa de correção entre as etapas de Adaptação e Combinação. Essa nova etapa é definida em (4.31). A etapa de combinação ocorre em seguida conforme (4.32). Os coeficientes da matriz de pesos \bar{a}_{ij} constituem outras matrizes estocásticas à esquerda além da Metropolis.

$$\phi_i^k = \varphi_i^k + \lambda_i^{k-1} - \phi_i^{k-1} \quad (4.31)$$

$$\lambda_i^k = \sum_{j \in N_i} \bar{a}_{ij} \phi_i^k \quad (4.32)$$

Em que:

- ϕ_i^k : variável etapa de correção.
- $\varphi_i^k, \varphi_i^{k-1}$: variáveis intermediárias provenientes da etapa de adaptação para as iterações k e $k - 1$.
- $\lambda_i^k, \lambda_i^{k-1}$: custo incremental do agente i nas iterações k e $k - 1$.

Os valores do ganho de feedback ε_i são adaptados como em (4.33) conforme (HE *et al.*, 2019). De acordo com o teorema de Perron-Frobenius, se a matriz é primitiva, então 1 é o único autovalor máximo da matriz, e p_i é o autovetor de Perron, ou seja, o autovetor correspondente ao máximo autovalor. I_N é uma matriz identidade. A matriz \bar{A} é uma matriz estocástica esquerda cujos elementos correspondem aos coeficientes de comunicação entre os agentes obtida através de (4.33)

$$\left\{ \begin{array}{l} \varepsilon_i = \frac{\varepsilon}{p_i} \\ \bar{A} = \frac{I_N + A}{2} \end{array} \right. \quad (4.33)$$

Em que:

- ε_i : ganho de *feedback* atualizado para Difusão Exata.
- p_i : autovetor de Perron.
- \bar{A} : matriz estocástica esquerda aplicada à difusão exata.
- I_N : matriz identidade.

$$a_{lk} = \begin{cases} \frac{\mu_k/q_k}{\max[n_k\mu_k/q_k, n_l\mu_l/q_l]}, l \in \Omega_k/k \\ 1 - \sum_{j \in \Omega_k} w_{jk}, l = k \\ 0, l \notin \Omega_k \end{cases} \quad (4.34)$$

$$a_{lk} = \begin{cases} 1/n_k, l \in \Omega_k \\ 0, l \notin \Omega_k \end{cases} \quad (4.35)$$

$$a_{lk} = \begin{cases} \frac{n_l}{\sum_{m \in \Omega_k} n_m}, l \in \Omega_k \\ 0, l \notin \Omega_k \end{cases} \quad (4.36)$$

Neste estudo, além da tradicional matriz obtida através do critério de Metropolis, foram adotadas outras matrizes de comunicação a fim de explorar esse novo recurso do método de Difusão Exata bem como verificar o desempenho do método em diferentes possibilidades, sendo esse mais um diferencial desse estudo. As outras matrizes estudadas foram as seguintes: *Hasting Rules*, *Averaging Rule* e *Relative Degree*.

4.3.6 Otimização do Ganho de Feedback

Para todos os métodos de obtenção do despacho econômico ótimo analisados nesse estudo, utiliza-se um ganho de *feedback* ε aplicado à diferença de potência ΔP_i na otimização por Consenso, e ao gradiente da função objetivo $\nabla_{\lambda} J_i$ na otimização por Difusão e Difusão Exata conforme (4.23) e (4.29). O termo ganho de *feedback*, que corresponde a um tamanho de passo, advém da característica de este ser aplicado aos fatores citados $(\Delta P_i, \nabla_{\lambda} J_i)$, que correspondem a um *feedback* de equilíbrio de potência. O ganho de *feedback* é um parâmetro importante que pode influenciar bastante na velocidade de convergência do algoritmo. Através da revisão bibliográfica, verificou-se que comumente, para métodos de otimização distribuída, adota-se esse ganho como um pequeno valor constante e comum a todos os agente. Entretanto, em (WANG *et al.*, 2018), é proposta a utilização de um ganho ε diferente para cada agente e variável com o tempo.

Neste estudo, analisou-se os métodos de otimização mais favoráveis quanto ao aspecto de esforço computacional, também foram adotadas estratégias que contribuem para essa característica como o aprimoramento do ganho de feedback. Assim, seguindo o que foi proposto

em (WANG *et al.*, 2018), foi aplicado neste trabalho um ganho de *feedback* variável para cada agente, a fim de se obter um despacho econômico ótimo com menor esforço computacional e necessidade de uma quantidade menor de iterações para se atingir a convergência. Em (WANG *et al.*, 2018) utilizou-se a ideia de um ganho de *feedback* variável no Consenso aplicado ao problema de despacho econômico de uma microrrede apenas com geradores despacháveis. Neste estudo, o ganho variável foi calculado através de Algoritmo Genético aplicado a cada um dos métodos de otimização. Além disso, foi aplicada a otimização desse ganho para o problema de despacho econômico de uma microrrede com recursos de geração despachável, geração renovável, sistema de armazenamento e cargas flexíveis, nos modos ilhado e conectado. Além disso, o ε variável foi estendido aos métodos de Difusão e Difusão Exata. Ressalta-se que no método de Difusão Exata, para a obtenção do ε ótimo, dividiu-se o valor obtido para cada agente através da Difusão Clássica pelo autovetor de Perron.

O algoritmo genético consiste em uma meta-heurística de otimização considerada robusta e de implementação simples e que apresenta bom desempenho em problemas com solução não diferenciável ou não convexa ainda que seja utilizada uma pequena população (CHENG; HWANG, 2001). Este método pertence ao grupo dos algoritmos que buscam utilizar os princípios da evolução biológica e da seleção natural para solucionar problemas, caracterizando a computação evolutiva.

No cerne da computação evolutiva, os indivíduos são compostos por cromossomos e cada cromossomo contém genes que representam características inerentes ao problema em análise. A união destas características forma um indivíduo que representa uma solução possível a ser avaliada através da execução do algoritmo evolutivo, neste caso o Algoritmo Genético.

O Algoritmo Genético é caracterizado por três etapas principais: Mutação, Cruzamento e Seleção. Através da mutação e cruzamento são realizadas perturbações na população inicial de forma a gerar indivíduos distintos. Através da seleção são determinados os indivíduos mais aptos, eliminando os demais. Cada nova população criada define uma nova geração. Assim, através da repetição dessa sequência de etapas são geradas diversas gerações de populações até que sejam atingidos os critérios de parada em que são selecionados os indivíduos mais aptos à luz da função de aptidão.

No Algoritmo Genético desenvolvido neste estudo, estabeleceu-se como função objetivo a determinação do conjunto de valores de ε que minimizariam o esforço computacional do algoritmo de otimização distribuída, caracterizado pelo número de iterações até a convergência.

Uma população inicial de 4000 conjuntos de ϵ iniciais foi criada, sua probabilidade de mutação foi definida em 7% e a adequação de cada membro da população corresponde ao valor final do número de iterações até a convergência. 15.000 cruzamentos foram realizadas para cada método de otimização.

Os valores obtidos para o modo ilhado são apresentados na Tabela 1 em que os números subscritos aos ganhos de *feedback* ϵ_i representam os agentes carga crítica, carga não-crítica, geração renovável, geração despachável e bateria, nesta ordem. Utilizou-se o algoritmo para o cálculo do ganho de *feedback* para 4 tipos de Matrizes de Peso na Difusão Exata, que estão dispostas na seguinte ordem na tabela: *Averaging Rule*, *Relative Degree*, *Mean Metropolis* e *Hasting Rules*. Na Tabela 2 são apresentados os ganhos de *feedback* obtidos para o modo conectado e os números subscritos representam os seguintes agentes: carga, geração renovável, geração despachável, bateria e rede.

Tabela 1 – Ganho de *feedback* dos agentes no modo ilhado

	ϵ_1	ϵ_2	ϵ_3	ϵ_4	ϵ_5
Consenso	0.0915	0.0979	0.0821	0.0834	0.0984
Difusão	0.4722	0.4659	0.4160	0.4603	0.4492
Difusão Exata 1	0.0713	0.0197	0.0089	0.5755	0.1326
Difusão Exata 2	0.4809	0.5103	0.5194	0.5029	0.494
Difusão Exata 3	0.1351	0.1391	0.297	0.5391	0.5379
Difusão Exata 4	0.0579	0.0544	0.0626	0.0644	0.0664

Fonte: Elaborada pelo autora.

Tabela 2 – Ganho de *feedback* dos agentes no modo conectado

	ϵ_1	ϵ_2	ϵ_3	ϵ_4	ϵ_5
Consenso	0.7859	0.9914	0.8724	0.8977	0.5641
Difusão	0.6227	0.7995	0.9701	0.9481	0.7073
Difusão Exata 1	0.9845	0.9313	0.7556	0.9480	0.9752
Difusão Exata 2	0.5928	0.7220	0.9448	0.8983	0.6244
Difusão Exata 3	0.9073	0.9059	0.8388	0.9891	0.2532
Difusão Exata 4	0.3864	0.2532	0.5065	0.6669	0.7137

Fonte: Elaborada pelo autora.

4.4 Desenvolvimento do Despacho Ótimo em Microrredes

Nesta seção será descrito o procedimento geral adotado para o despacho econômico em microrredes. O procedimento é bastante similar entre os métodos, havendo etapas adicionais para a Difusão e Difusão Exata. Portanto, será descrito o processo de despacho ótimo para a Difusão Exata que possui mais etapas. Na Difusão clássica deve-se desconsiderar a segunda variável intermediária calculada na Difusão Exata (ϕ_i), além de fazer a adaptação para os coeficientes de peso utilizados no cálculo do custo incremental. Para o processo de Consenso, não há as etapas de Adaptação e Combinação inerentes ao método de Difusão.

Inicialmente é formada a Matriz de Adjacências que modela o compartilhamento de informação entre os agentes. A seguir, define-se os parâmetros dos agentes: coeficientes de custo, valores máximos e mínimos de potência, estado de carregamento da bateria, potência renovável disponível, carga flexível e carga crítica.

Na segunda etapa do desenvolvimento, são inicializadas as variáveis que controlam parâmetros e analisam a convergência e o equilíbrio de potências do problema. Dentre essas variáveis existem flags sinalizadoras individuais aos agentes. Essas flags são úteis ao agente para indicar a ultrapassagem de algum dos limites de potência, quando correspondem ao valor 1, indicam que o agente correspondente ultrapassou a potência máxima ou mínima no processo de otimização. Além disso, há três listas que dividem os agentes entre os que ultrapassaram a potência máxima, mínima ou que não ultrapassaram os limites de potência. O conjunto das flags, sinalizando a ultrapassagem de algum dos limites de potência e a lista indicando se a potência violada foi a mínima ou a máxima interfere na atualização de potência do agente. Esse trecho do código é representado na Figura 15.

Figura 15 – *Flags* sinalizadoras de ultrapassagem de potência

```
flag=np.zeros(nG)

Plim_sup = np.array([0,0,50,(soc*pmaxess),0])
Plim_inf = np.array([0,0,0,-(1-soc)*pmaxess,0])
#Agentes que ultrapassaram a Potência Máxima:
P_u_max=[]

#Agentes que ultrapassaram a Potência Mínima:
P_u_min=[]

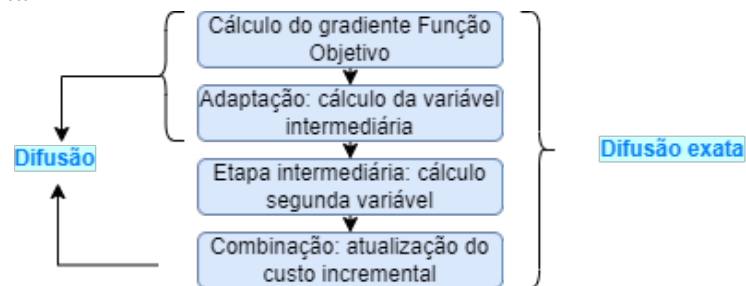
#Agentes que não ultrapassaram os limites de potência :
P_n=[]
```

Fonte: Própria da autora

Na terceira etapa do processo, será iniciado o processo de otimização. Esse processo ocorre duas vezes. Na primeira vez, a otimização é feita sem restrição de potência quanto aos valores máximos e mínimos de cada agente. Assim, conforme proposto em (WANG *et al.*, 2018), na primeira rodada da otimização, os agentes atualizam a potência livremente, baseando-se no custo incremental a cada iteração conforme (4.25). Quando houver a convergência, os agentes verificam se a sua potência resultante do processo de otimização está dentro de suas restrições, sinalizando, conforme o caso a *flag* e, através da lista, se a potência ultrapassada foi a máxima ou a mínima. Caso haja alguma ultrapassagem de potência, na segunda rodada de otimização, os agentes sinalizados, irão atualizar a potência para o seu valor máximo ou mínimo conforme o caso. Para cada rodada de otimização, são inicializados os custos e variáveis intermediárias.

Na quarta etapa, é feita a atualização do custo incremental que varia conforme o método. Na Difusão Exata há as etapas de Adaptação, Correção e Combinação. Na Difusão, há as etapas de adaptação e combinação. Esse trecho do código é demonstrado através do fluxograma na Figura 16

Figura 16 – Fluxograma da Atualização do Custo Incremental



Fonte: Própria da autora

Na quinta etapa, com o custo incremental sendo atualizado a cada iteração, as potências também devem ser atualizadas. Caso a otimização esteja rodando pela primeira vez ou, a análise de potência para a segunda rodada demonstre que o agente atendeu às restrições de potência, atualiza-se a potência conforme o custo incremental e coeficientes de custo. Caso haja ultrapassagem de potências, as potências serão atualizadas conforme o valor máximo ou mínimo. Essa etapa está ilustrada na Figura 17. Após a atualização de potência, verifica-se, para cada agente a diferença de custo incremental da iteração atual para iteração anterior. Caso essa diferença seja muito pequena, sinaliza-se uma convergência. Neste trabalho, o critério de parada adotado foi uma diferença de custo incremental entre uma iteração e outra de 0.0001.

Por fim, na sexta etapa, após a convergência do algoritmo, será feita uma análise

das potências resultantes por parte de cada um dos agentes, separando-as nas listas citadas e acionando as flags necessárias. Caso seja verificada a ultrapassagem de potência pelo agente, sua respectiva flag será acionada para que, na segunda rodada de otimização, a sua atualização de potência siga o valor máximo ou mínimo. O fluxograma da Figura 18 resume o procedimento descrito.

Figura 17 – Etapa de Atualização de Potências

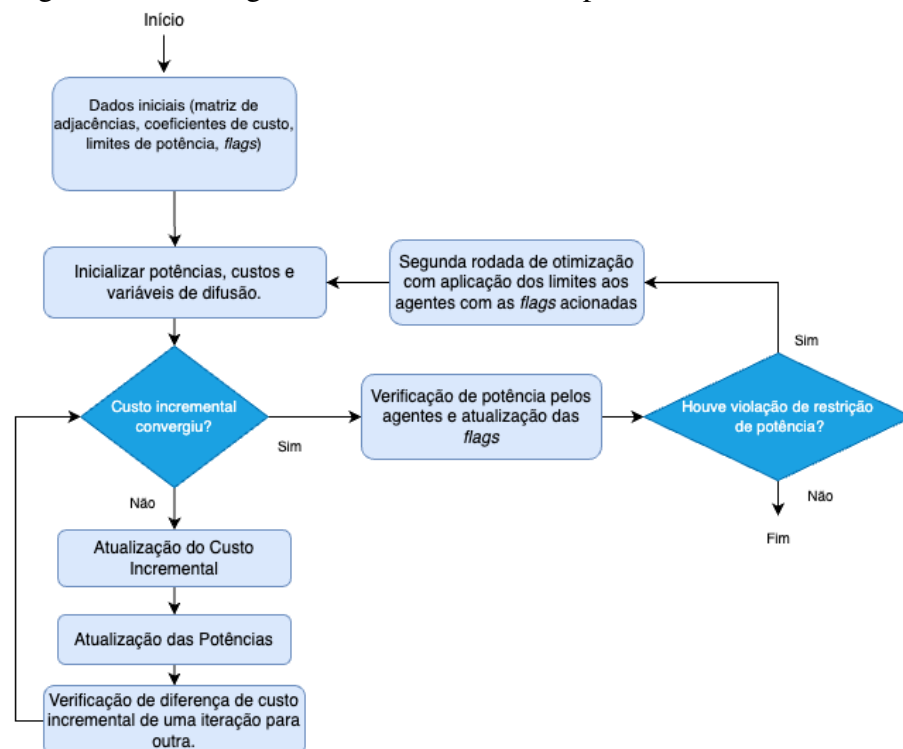
```

if j in Desp:
    if j in P_n or n_algorit==0:
        Pg[i+1,j] = (r[i+1,j] - bet[j])/(2*alp[j])
    elif j in P_u_max:
        Pg[i+1,j]=Plim_sup[j]
    elif j in P_u_min:
        Pg[i+1,j]=Plim_inf[j]

```

Fonte: Própria da autora

Figura 18 – Fluxograma do Processo de Despacho Econômico



Fonte: Própria da autora

4.5 Considerações Finais

Este capítulo apresentou a modelagem do problema de despacho econômico em uma microrrede ilhada e conectada bem como dos seus recursos. Além disso, os métodos

de otimização apresentados no Capítulo 3 foram aplicados ao problema de despacho em uma microrrede, apontando as estratégias desenvolvidas nesse estudo para tornar mais eficiente e robusto o gerenciamento dos recursos de uma microrrede.

5 CENÁRIOS SIMULADOS E RESULTADOS

5.1 Introdução

Neste capítulo, os métodos de otimização distribuída de Consenso, Difusão e Difusão Exata serão empregados em diferentes cenários de carga, geração renovável e estado de carregamento da bateria, bem como no modo ilhado e conectado à rede externa. Diante desses cenários, serão avaliados os resultados obtidos, bem como o desempenho dos métodos quanto a alguns aspectos que caracterizam o esforço computacional.

5.2 Configuração dos Agentes e Parâmetros Analisados

Na comparação dos métodos, inicialmente verificou-se a assertividade dos métodos comparando-se os resultados de custo incremental e potência final obtido a partir da execução de cada método. Além disso, analisou-se se as restrições de potência de cada agente, bem como o equilíbrio entre oferta e demanda foram atendidos. Outro aspecto analisado foi o esforço computacional. Segundo (COSTA; SILVA, 2009), o esforço computacional de um método de otimização é medido pelo número de operações efetuadas a cada iteração, da complexidade destas operações e pelo número de iterações até a convergência. Esses, portanto, foram os itens avaliados para fins de verificação do esforço computacional relacionado a cada método. Além disso, foi analisada a rapidez da convergência conforme proposto em (COSTA; SILVA, 2009) através do número de iterações e do tempo até a convergência. O sistema foi executado em computador pessoal com processador Intel Core i7-9750H CPU @2.60GHz x64 com 8 GB RAM.

Abordando a configuração dos agentes, os parâmetros das funções custo do agente geração despachável e os limites de potência adotados são apresentados na Tabela 3. Os parâmetros da função custo do agente bateria para os modos ilhado e conectado são apresentados na Tabela 4. Na Tabela 5 são apresentados os parâmetros da função utilidade que modela os agentes carga para operação em modo ilhado.

Tabela 3 – Parâmetros Agente Geração Despachável

AGENTE	α	β	γ	$P_{DG}^{max}(kW)$	$P_{DG}^{min}(kW)$
DG	0.18	97	50	50	0

Fonte: Própria da autora

Tabela 4 – Parâmetros Agente Bateria

Agente Bateria	α	β	γ	$P_B^{max}(kW)$
Modo Ilhado	2	8	30	40
Modo Conectado	0.3	114	50	40

Fonte: Própria da autora

Tabela 5 – Parâmetros Função Utilidade

Cenário	Carga crítica		Carga não crítica	
	w	v	w	v
Cenário 1	-44.46	-1.482	-36.33	-1.953
Cenário 2	-44.46	-1.383	-36.33	-1.159
Cenário 3	-900.44	-20.98	-200.25	-6.675

Fonte: Própria da autora

5.3 Cenários de Modo Ilhado

5.3.1 Cenário 1

No primeiro Cenário do modo ilhado foi simulada uma situação de carga baixa e baixo carregamento da bateria a fim de testar o seu carregamento. Os valores de geração renovável e carga desse cenário estão dispostos na Tabela 6.

No Cenário 1, os resultados obtidos pelos diferentes métodos de despacho quanto ao custo incremental, tempo e número de iterações até a convergência e potência final dos agentes são apresentados na Tabela 7. O valor total de potência dos dois agentes carga foi somado e representado como P_c . A contribuição do agente geração renovável é considerada nas variáveis de inicialização e sua contribuição para o balanço de potência pode ser verificada na Tabela 6. Esses resultados permitem a análise quanto à compatibilidade de resultados obtidos para os diferentes métodos e ao comportamento dos agentes. Além disso, pode-se verificar a velocidade de convergência, que é medida através do tempo de convergência e número de iterações até a convergência.

Neste cenário, verifica-se o carregamento da bateria em uma condição de baixa carga e baixo SOC, conforme o esperado. Observa-se que o método de Difusão apresentou um desempenho superior aos outros métodos quanto ao número de iterações necessárias até

Tabela 6 – Cenários Simulados - Modo Ilhado

Cenários Simulados	P_{ren} (kW)	P_c Crítica (kW)	P_c não crítica (kW)	SOC
Cenário 1	10	30	18.6	0.2
Cenário 2	8.5	32.15	31.34	0.4
Cenário 3	13.15	42.9	30	0.1

Fonte: Própria da autora

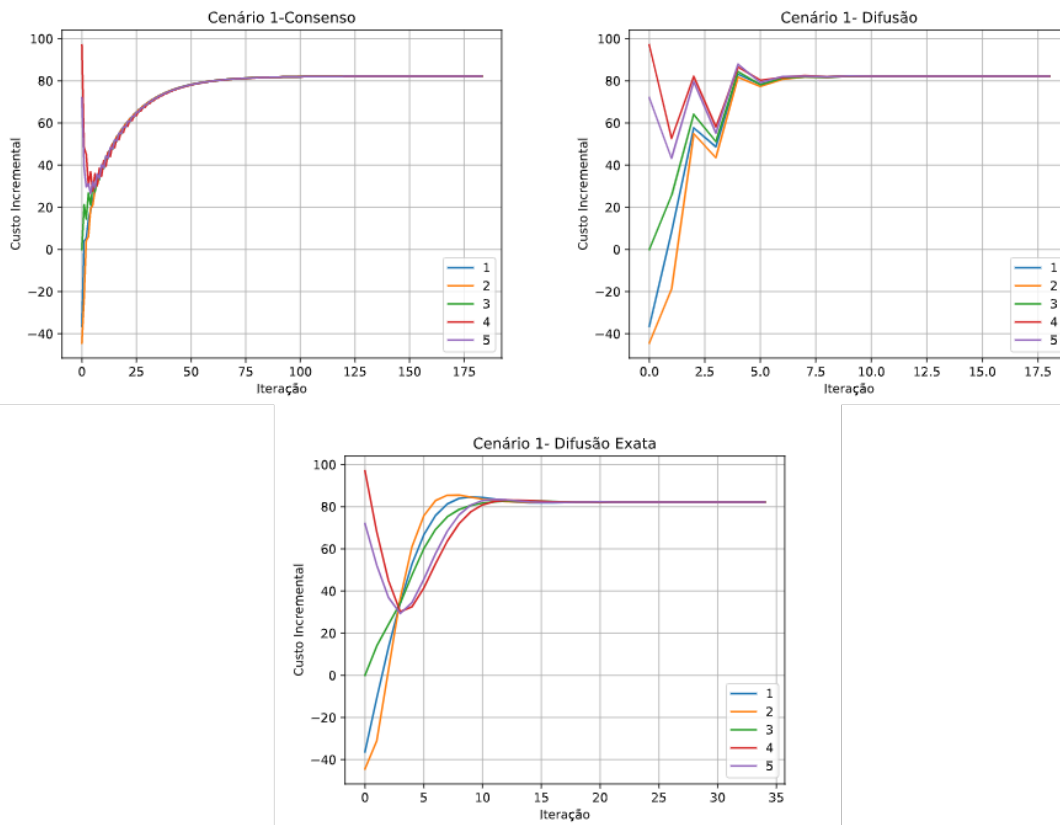
Tabela 7 – Resultados Cenário 1

Método	P_{DG} (kW)	P_B (kW)	P_C (kW)	λ	Iterações	Tempo de convergência (ms)
Consenso	41.15	-2.55	-48.6	82.19	184	13
Difusão	41.15	-2.55	-48.6	82.19	19	4
Difusão Exata	41.15	-2.55	-48.6	82.19	35	4
<i>Averaging Rule</i>	41.15	-2.55	-48.6	82.19	50	5
Difusão Exata	41.15	-2.55	-48.6	82.19	55	8
<i>Relative Degree</i>	41.15	-2.55	-48.6	82.19	51	6
Difusão Exata	41.15	-2.55	-48.6	82.19	51	6
<i>Mean Metropolis</i>	41.15	-2.55	-48.6	82.19	51	6
Difusão Exata	41.15	-2.55	-48.6	82.19	51	6
<i>Hasting Rules</i>	41.15	-2.55	-48.6	82.19	51	6

Fonte: Própria da autora

a convergência, além de um tempo reduzido até a convergência. Apesar disso, nota-se que o tempo mínimo até a convergência é bastante similar entre os métodos de Difusão e Difusão Exata, apontando que o número maior de iterações até a convergência da Difusão Exata quando compara à Difusão, não provoca necessariamente em um tempo significativamente maior até a convergência, verificando-se uma velocidade de convergência bastante similar entre os métodos. Além disso, verifica-se que no método de Difusão Exata, o uso de diferentes matrizes garantiu a convergência, porém com diferente número de iterações, tendo a matriz de pesos *Averaging Rule* a de melhor resposta. Para esse cenário, na Figura 19, é possível observar a diferença da evolução do custo incremental com relação ao número de iterações entre os métodos de Consenso, Difusão e Difusão Exata com a matriz *Averaging Rule*, cujo desempenho foi superior dentre as outras matrizes utilizadas na Difusão Exata. Na Figura, os valores de 1 a 5 representam os 5 agentes na seguinte ordem: carga não crítica, carga crítica, geração renovável, geração despachável e bateria.

Figura 19 – Resultados Cenário 1



Fonte: Própria da Autora

5.3.2 Cenário 2

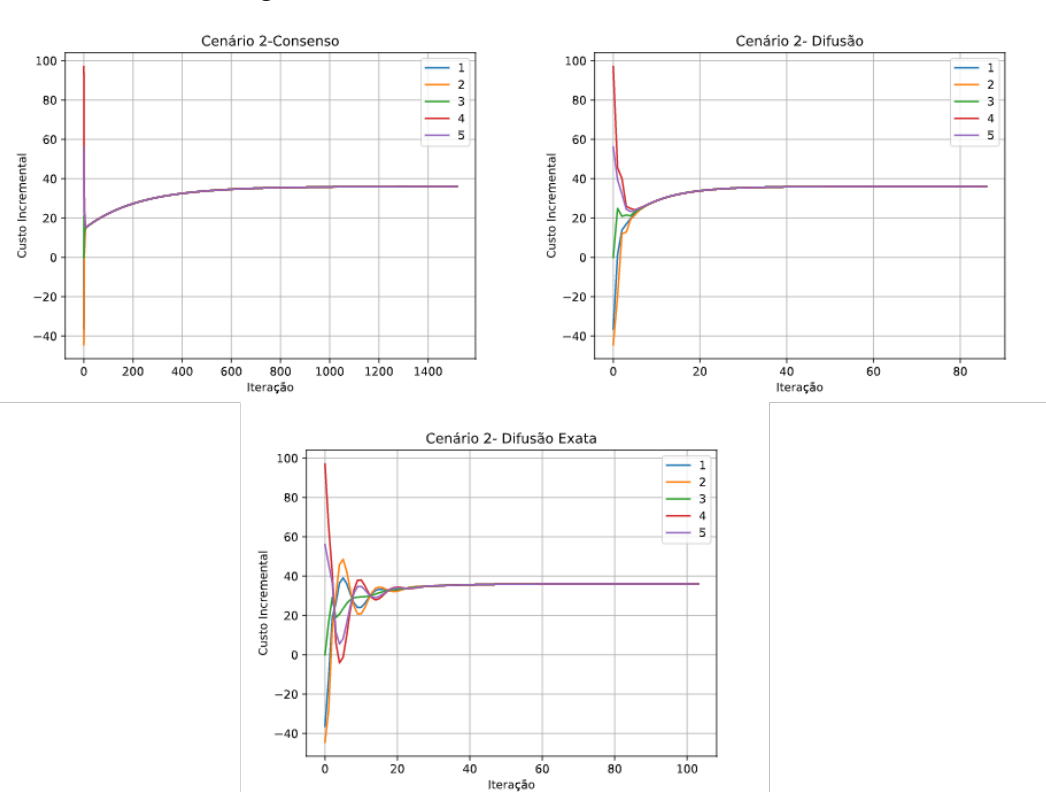
Para o Cenário 2, os resultados são representados na Tabela 8. Verifica-se que para uma carga e SOC intermediários, não há a necessidade de corte de carga e constata-se que a bateria contribui para o suprimento da carga conforme esperado. Os resultados obtidos pelos diferentes métodos são bastante similares, o que contribui para validar os valores obtidos. Além disso, observa-se que as restrições do problema foram obedecidas, havendo o equilíbrio de potência entre os agentes fontes e cargas, cujos valores limite de potência também foram atendidos. O desempenho quanto ao parâmetro de velocidade de convergência é bastante similar entre os métodos de Difusão e Difusão Exata, pois, simultaneamente, verifica-se um menor número de iterações para a Difusão e um menor tempo de convergência para alguns tipos de matrizes da Difusão Exata, a saber: *Averaging Rule* e *Hasting Rules*. Essas duas últimas matrizes apresentaram o melhor desempenho quanto ao aspecto de velocidade de convergência na Difusão Exata. Na Figura 20 é apresentada a diferença da evolução do custo incremental com relação ao número de iterações entre os métodos de Consenso, Difusão e Difusão Exata com a matriz *Averaging Rule*.

Tabela 8 – Resultados Cenário 2

Método	P_{DG} (kW)	P_B (kW)	P_C (kW)	λ	Iterações	Tempo de convergência (ms)
Consenso	50	4.99	-63.49	36.02	1518	88
Difusão	50	4.99	-63.49	36.04	87	12
Difusão Exata	50	4.99	-63.49	36.04	104	8
Averaging Rule	50	4.99	-63.49	36.04	375	14
Difusão Exata	50	4.99	-63.49	36.04	192	12
Relative Degree	50	4.99	-63.49	36.04	55	6
Difusão Exata	50	4.99	-63.49	36.04	192	12
Mean Metropolis	50	4.99	-63.49	36.04	55	6
Difusão Exata	50	4.99	-63.49	36.04	55	6
Hasting Rules	50	4.99	-63.49	36.04	55	6

Fonte: Própria da autora

Figura 20 – Resultados Cenário 2



Fonte: Própria da Autora

5.3.3 Cenário 3

Para o Cenário 3, os resultados são representados na Tabela 9. Há uma carga elevada e os recursos da microrrede não são suficientes para atendê-la. Verifica-se, conforme modelado, o corte de parcela da carga flexível, havendo um benefício incremental associado a esse corte.

Tabela 9 – Resultados Cenário 3

Método	P_{DG} (kW)	P_B (kW)	P_C (kW)	λ	Iterações	Tempo de convergência (ms)
Consenso	50	4	-67.14	-38.84	2364	230
Difusão	50	4	-67.15	-38.81	125	15
Difusão Exata <i>Averaging Rule</i>	50	4	-67.15	-38.38	155	13
Difusão Exata <i>Relative Degree</i>	50	4	-67.15	-38.39	591	29
Difusão Exata <i>Mean Metropolis</i>	50	4	-67.15	-38.39	391	22
Difusão Exata <i>Hasting Rules</i>	50	4	-67.15	-38.39	759	43

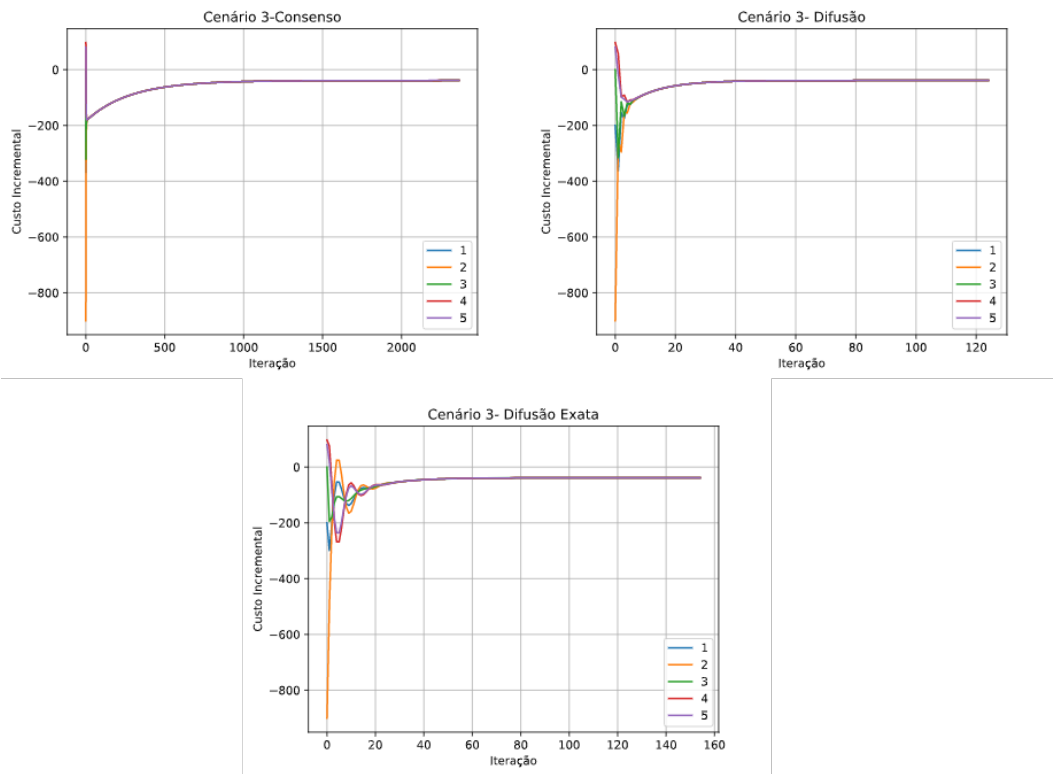
Fonte: Própria da autora

A carga líquida desse cenário, considerando a contribuição da geração renovável, é de 61.75 kW. Os recursos da MR com capacidade máxima de suprimento de 54 kW implicou em um corte de 7.75 kW. O algoritmo prioriza o corte da parcela de carga não crítica com relação à carga prioritária, uma vez que a prioritária possui um benefício marginal maior. O valor final do custo incremental é negativo, sinalizando o corte de carga, que irá maximizar o benefício associado. Os resultados obtidos a partir dos diferentes métodos foram compatíveis, seguindo o mesmo padrão dos cenários anteriores. A Difusão atinge a convergência com um número menor de iterações e menor tempo. Para Difusão Exata, a matriz *Averaging Rule* apresentou menor número de iterações e tempo até a convergência, verificando-se que, através da sua utilização na Difusão Exata, há uma maior proximidade de desempenho quanto ao aspecto de velocidade de convergência com a Difusão. Na Figura 21, verifica-se a diferença da evolução do custo incremental com relação ao número de iterações entre os métodos de Consenso, Difusão e Difusão Exata com a matriz *Averaging Rule*.

5.4 Cenários de Modo Conectado

Para o modo conectado foram simulados três cenários com diferentes tarifas. Dois cenários caracterizam situações pontuais. O terceiro cenário abrangeu uma previsão de 24 horas, a fim de ilustrar o comportamento dinâmico dos agentes para diferentes previsões de geração renovável e carga. Em um dos cenários, no cenário 4, verifica-se uma tarifa mais baixa, o que provoca a compra de energia da rede externa para o suprimento de cargas e carregamento da

Figura 21 – Resultados Cenário 3



Fonte: Própria da Autora

Tabela 10 – Cenários Simulados - Modo Conectado

Cenários Simulados	P_{ren} (kW)	P_C (kW)	SOC
Cenário 1	9	44.1	0.1
Cenário 2	10	40	0.9

Fonte: Própria da Autora

bateria da MR. No outro cenário, com tarifa mais elevada, a MR tende a fornecer potência para a rede externa. Os valores de entrada dos cenários simulados são apresentados na Tabela 10.

5.4.1 Cenário 4

No Cenário 4, verifica-se uma condição representativa de utilização da rede externa para o suprimento de cargas e carregamento da bateria. Na Tabela 11 são apresentados os resultados obtidos para potência de cada agente e do custo incremental resultante, que é equivalente à tarifa de energia, correspondendo à operação ótima para este modo. Nesse cenário, os limites de potência de cada agente foram obedecidos, verificando-se que não houve a participação do gerador despachável para o suprimento da demanda da MR, visto que os coeficientes de custo

Tabela 11 – Resultados Cenário 4

Método	P_{DG} (kW)	P_B (kW)	P_D (kW)	P_R (kW)	λ	Iterações	Tempo de Convergência (ms)
Consenso	0	-36	-35.1	71.1	95	69	16
Difusão	0	-36	-35.1	71.1	95	45	8
Difusão Exata Averaging Rule	0	-36	-35.1	71.1	95	102	24
Difusão Exata Relative Degree	0	-36	-35.1	71.1	95	107	25
Difusão Exata Mean Metropolis	0	-36	-35.1	71.1	95	131	31
Difusão Exata Hasting Rules	0	-36	-35.1	71.1	95	37	7

Fonte: Própria da autora

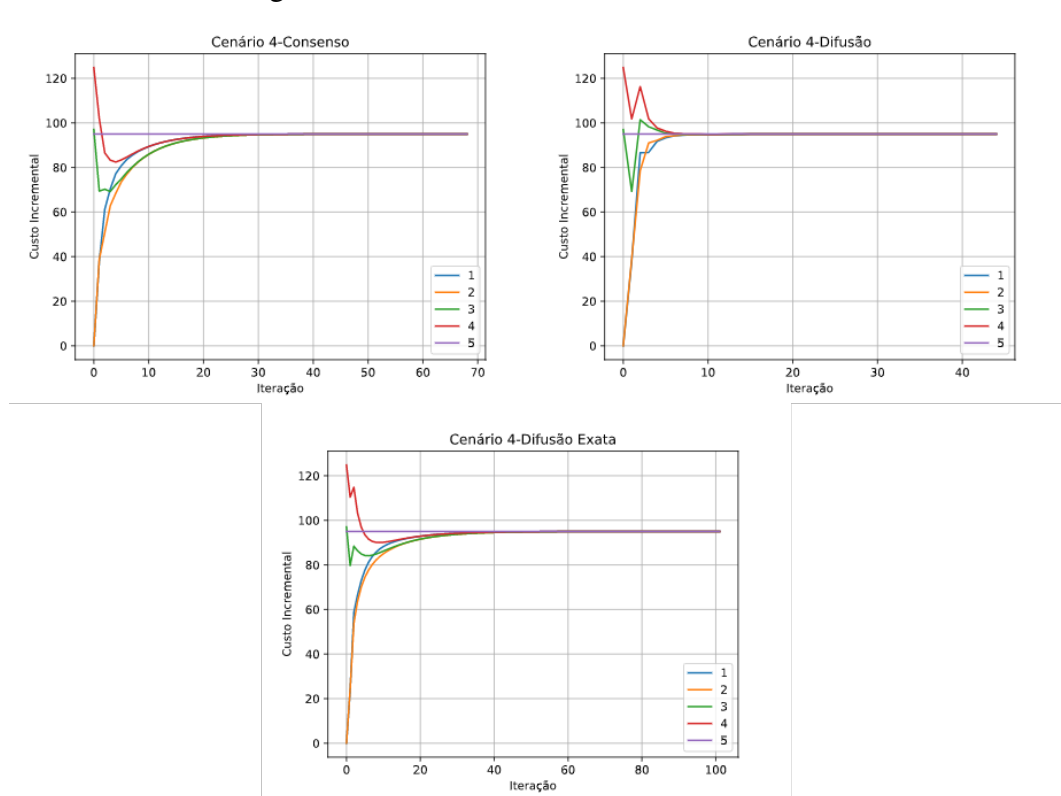
dessa fonte são superiores à tarifa de rede. Além disso, verificou-se o carregamento da bateria em um cenário de baixo SOC e tarifa mais baixa. A rede foi utilizada para o suprimento da demanda líquida da MR e carregamento da bateria. Todos os métodos apresentaram resultados equivalentes. Na Figura 22, verifica-se a diferença da evolução do custo incremental com relação ao número de iterações entre os métodos de Consenso, Difusão e Difusão Exata com a matriz *Hasting Rules*. Na figura, os valores de 1 a 5 representam os 5 agentes do modo conectado na seguinte ordem: carga, geração renovável, geração despachável, bateria e rede.

No aspecto de velocidade de convergência, verificou-se que o melhor desempenho ocorreu através da Difusão Exata com a aplicação da Matriz *Hasting Rules*. Esse desempenho, entretanto, diferiu bastante da Difusão Exata através de outras matrizes, que apresentaram menor velocidade de convergência que o Consenso. No método de Difusão, mais uma vez verificou-se um desempenho bastante satisfatório quanto à velocidade de convergência, comparável à Difusão Exata utilizando a matriz *Hasting Rules*. O tempo de convergência dos agentes acompanhou à tendência verificada quanto ao número de iterações e os melhores resultados foram verificados na Difusão e Difusão Exata com a matriz *Hasting Rules*, que apresentam, portanto, velocidade de convergência similar.

5.4.2 Cenário 5

No Cenário 5, verifica-se um cenário representativo de fornecimento de energia para rede externa através de recursos da MR, cujos coeficientes de custo se encontram inferiores à

Figura 22 – Resultados Cenário 4



Fonte: Própria da Autora

tarifa da rede. Na Tabela 12 são apresentados os resultados obtidos para potência de cada agente e do custo incremental resultante, que é equivalente à tarifa de energia, correspondendo à operação ótima para este modo. Nesse cenário, os limites de potência de cada agente foram obedecidos, verificando-se que o gerador despachável foi utilizado para o suprimento da demanda da MR, carregamento da bateria e fornecimento para rede externa. Na Figura 23, verifica-se a diferença da evolução do custo incremental com relação ao número de iterações entre os métodos de Consenso, Difusão e Difusão Exata com a matriz *Hasting Rules*.

Abordando o aspecto de velocidade de convergência, o método que obteve o melhor desempenho foi a Difusão, seguida do Consenso. Nesse cenário, novamente a Difusão usando a matriz *Hasting Rules* apresentou uma maior velocidade de convergência, entretanto, o número de iterações e tempo até a convergência foi mais próximo ao obtido com as demais matrizes.

5.4.3 Cenário 6

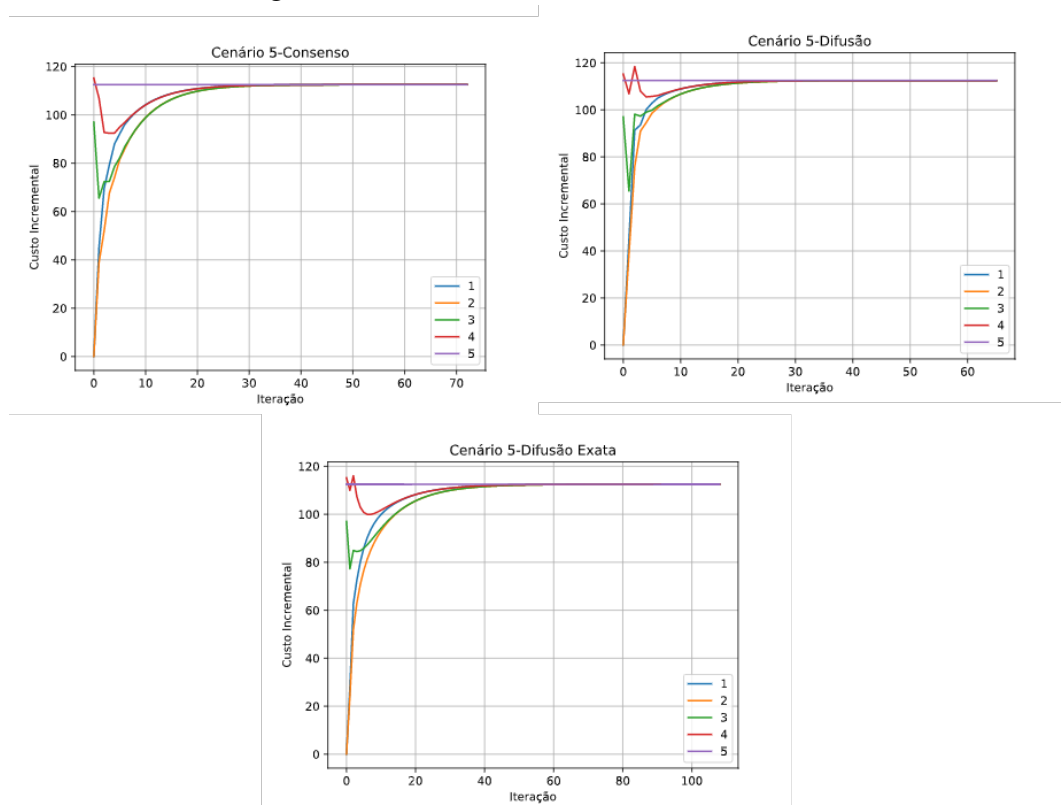
No Cenário 6, foi utilizada a previsão durante 24 horas, para janelas temporais de 1 hora, de geração renovável (eólica e fotovoltaica) e carga disponíveis em (ALI *et al.*, 2020). Na Figura 24 é apresentada esta previsão, que foi utilizada neste Cenário. Os valores de geração

Tabela 12 – Resultados Cenário 5

Método	P_{DG} (kW)	P_B (kW)	P_D (kW)	P_R (kW)	λ	Iterações	Tempo de Convergência (ms)
Consenso	43.05	-4	-30	-9.05	112.5	71	19
Difusão	43.05	-4	-30	-9.05	112.5	66	16
Difusão Exata	43.05	-4	-30	-9.05	112.5	109	24
<i>Averaging Rule</i>	43.05	-4	-30	-9.05	112.5	112	31
Difusão Exata	43.05	-4	-30	-9.05	112.5	137	32
<i>Relative Degree</i>	43.05	-4	-30	-9.05	112.5	91	21
Difusão Exata	43.05	-4	-30	-9.05	112.5		
<i>Mean Metropolis</i>	43.05	-4	-30	-9.05	112.5		
Difusão Exata	43.05	-4	-30	-9.05	112.5		
<i>Hasting Rules</i>	43.05	-4	-30	-9.05	112.5		

Fonte: Própria da autora

Figura 23 – Resultados Cenário 5



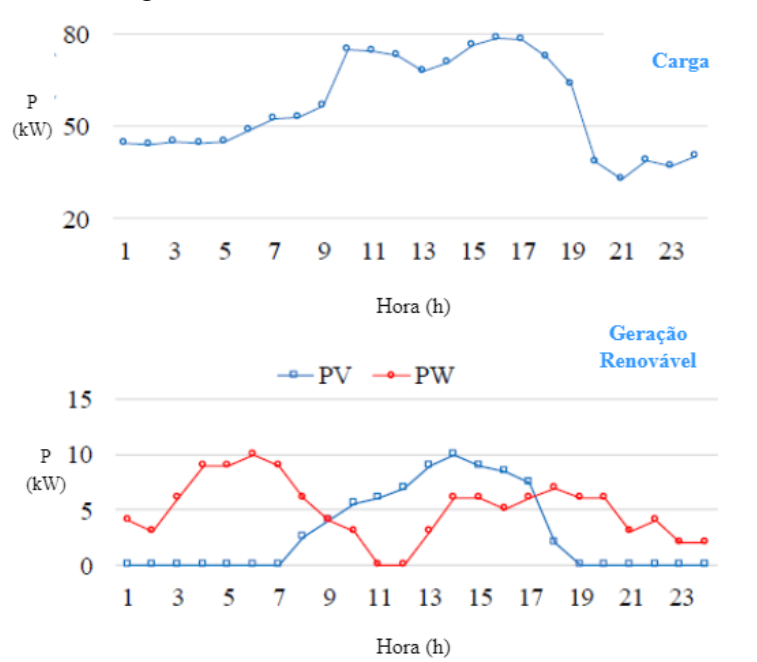
Fonte: Própria da Autora

renovável e carga foram utilizados como entrada no problema de despacho para a MR conectada com 2 valores diferentes de tarifa do agente rede durante as 24 horas. No período de 0 às 17horas e 22 às 0horas, foi considerada a tarifa mais baixa, de 95. Para o período de 18 às 21 horas, foi considerada a tarifa mais alta de 112.5. Visto que o objetivo deste cenário é analisar o

comportamento dinâmico dos agentes e não comparar parâmetros de velocidade de convergência dos diferentes métodos, utilizou-se o método de Difusão. O estado de carregamento inicial da bateria adotado foi de 0.2.

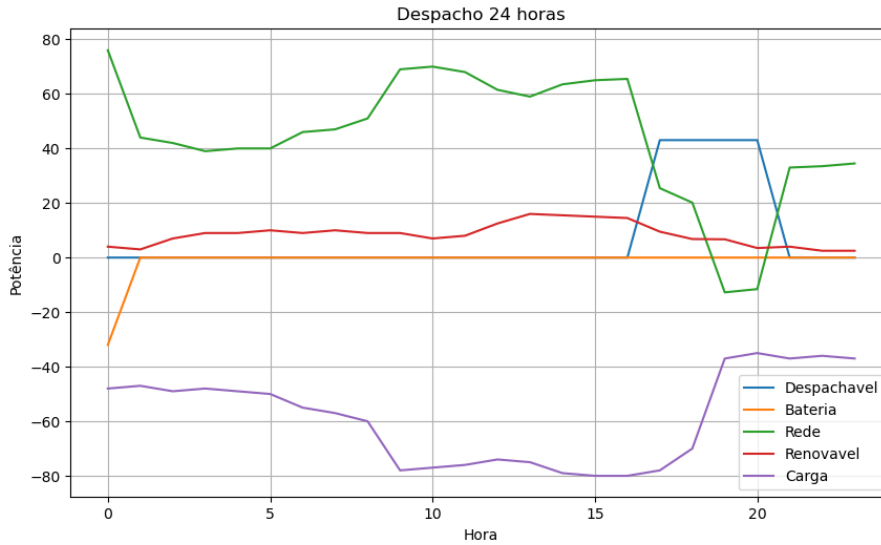
Na Figura 25, são apresentadas a variação de potência dos 5 agentes do modo conectado para o período de 24 horas. Primeiramente, percebe-se que o agente bateria, que inicialmente estava com um estado de carregamento baixo, e que possui um custo bastante superior aos outros agentes carrega totalmente. Durante o período restante, a bateria permanece totalmente abastecida sem carregar ou descarregar em conformidade com o esperado, pois mesmo em períodos de tarifa mais alta, a bateria possui um custo superior, não devendo contribuir com o abastecimento de cargas. Quanto ao agente rede, durante a maior parte do tempo, por possuir custo mais baixo, verifica-se a sua contribuição para o suprimento total das cargas da MR. A rede só será abastecida com os recursos da MR durante o período de tarifa mais elevada. Ainda assim, no período inicial de tarifa mais elevada, o agente rede ainda contribui com o abastecimento das cargas da MR, cujo valor encontra-se elevado e, portanto, o gerador despachável é insuficiente para o seu abastecimento. Por fim, verifica-se que o agente geração despachável só contribui com o abastecimento das cargas em períodos de tarifa mais alta.

Figura 24 – Previsão de Geração Renovável e Carga



Fonte: (ALI *et al.*, 2020), adaptado

Figura 25 – Resultado Cenário 6



Fonte: Própria da Autora

5.5 Comparação dos Métodos quanto ao Esforço Computacional

Nas seções anteriores, os métodos distribuídos em análise foram comparados quanto aos resultados obtidos e velocidade de convergência. Nesta seção, será feita uma análise de aspectos que caracterizam o esforço computacional. Em (COSTA; SILVA, 2009), afirma-se que o esforço computacional é caracterizado pelo número de iterações, número de operações por iteração e complexidade das operações. Neste trabalho foram analisados o número de iterações e o número de operações por iteração.

Quanto ao número de iterações, considerando-se, primeiramente, o método Consenso, notou-se no modo ilhado um número bastante elevado de iterações até a convergência e muito superior aos demais métodos. No modo conectado, em que o agente rede permanece compartilhando o valor da tarifa ao longo das iterações, o que contribui para uma convergência mais rápida, verificou-se uma significativa redução do número de iterações e uma maior proximidade de desempenho com os demais métodos. A Difusão, em ambos os modos, se destacou por convergir com poucas iterações. No Cenário 4, em que a Difusão convergiu com mais iterações que a Difusão Exata com a matriz *Hasting Rules*, essa diferença foi pouco significativa. A Difusão Exata apresentou um padrão variável de número de iterações até a convergência. No modo ilhado, verificou-se um número pequeno de iterações até a convergência comparável à Difusão para Difusão Exata através da matriz *Averaging Rule*; as demais matrizes apresentaram maior número de iterações até a convergência, entretanto, em quantidade bastante inferior ao

Consenso. No modo conectado, apesar de, normalmente, a Difusão Exata, convergir com maior quantidade de iterações, esse valor não supera significativamente os demais métodos.

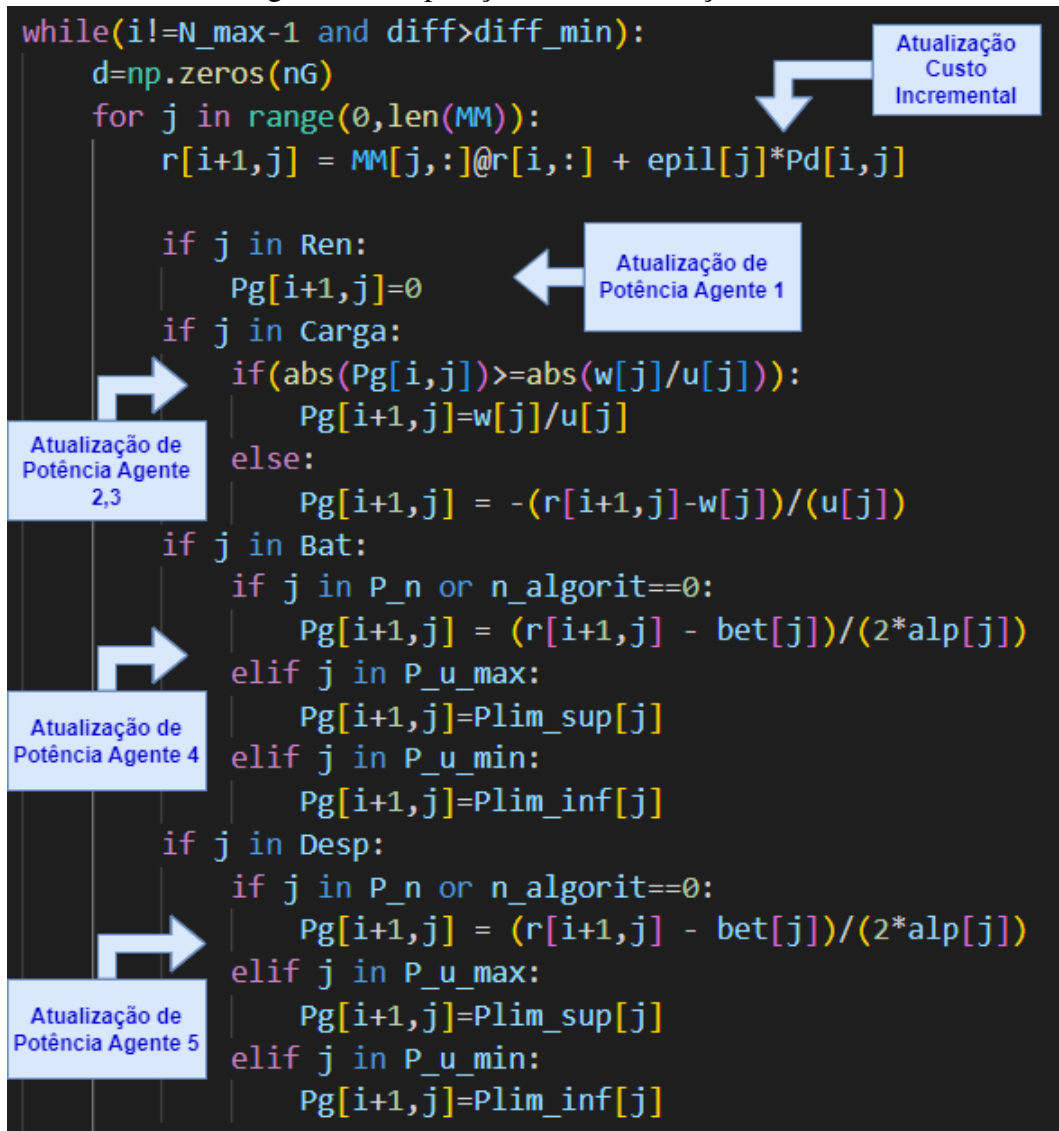
Analisando o número de operações por iteração, que também caracteriza o esforço computacional, verifica-se na Figura 26 as operações a cada iteração para o Consenso. A cada iteração, as operações realizadas consistem em: atualização do custo incremental e atualização de potência para cada agente. Para Difusão, há operações a mais a cada iteração, pois o custo incremental é atualizado em duas etapas: adaptação e combinação. Na etapa de adaptação, cada um dos 5 agentes gera uma variável intermediária. Logo, a cada iteração, há 5 operações a mais. Para a Difusão Exata, a atualização do custo incremental é feita em três etapas: adaptação, correção e combinação. Assim, com relação ao Consenso, há 5 operações a mais de adaptação e 5 operações a mais de correção para um cenário de 5 agentes. Portanto, percebe-se que apesar de o número de iterações do Consenso ser maior em cenários de modo ilhado, o número de operações por iteração é o menor dentre os métodos. Entretanto, verifica-se que a grande diferença do número de iterações entre o Consenso e os demais métodos no modo ilhado torna a diferença do número de operações por iteração pouco significativa. Já o número de iterações bastante similar entre os métodos Consenso e Difusão no modo conectado, justificaria o uso do Consenso, ao se considerar o esforço computacional, por possuir um número menor de operações por iteração.

5.6 Comparação dos Métodos quanto à Privacidade

Um outro fator relevante que pode ser considerado na escolha de um método de otimização é a privacidade das informações dos agentes. Analisou-se a privacidade dos métodos considerando duas perspectivas: informação compartilhada e matrizes de comunicação adotadas. Primeiramente, quanto à informação difundida, o Consenso e irá compartilhar o custo incremental e o valor do *mismatch* de cada um dos agentes com os agentes vizinhos, o que diminui a privacidade dos agentes. Quanto à Difusão, verifica-se uma maior privacidade de informação dos agentes quando comparado ao Consenso, pois os agentes não necessitam mais compartilhar o custo incremental, e sim uma variável que não possui significado físico. A Difusão Exata compartilha somente a variável de difusão, o que garante maior privacidade de informação assim como na Difusão.

Analisando a privacidade de informação através da perspectiva de matrizes utilizadas, os métodos Consenso e Difusão, utilizam matrizes duplamente estocásticas como a *Mean Metropolis* em que o usuário deve compartilhar o número de agentes com os quais se comunica.

Figura 26 – Operações de uma iteração



Fonte: Própria da Autora

Ao adotar a Difusão Exata, utilizando-se a matriz *Averaging Rules*, necessita-se apenas de um dado geral do número de usuários que utiliza a rede, não necessitando-se do número de vizinhos de cada agente. Assim, a adoção da Difusão Exata com matriz *Averaging Rules* proporciona maior privacidade com relação às demais matrizes, em que a privacidade de informação é equivalente à Difusão.

5.7 Considerações Finais

Neste Capítulo avaliou-se a modelagem dos agentes e do problema em diferentes cenários, verificando-se que a performance atingida correspondeu às características esperadas para os agentes ao mesmo tempo em que as restrições do problema foram atendidas. Além

disso, foram aplicadas as estratégias desenvolvidas neste trabalho para aprimorar os métodos distribuídos em análise, a saber o ganho de *feedback* variável e o controle de potência. Por fim, foi comparada a velocidade de convergência e esforço computacional entre os métodos, em que percebeu-se variações de comportamento de acordo com a matriz de pesos adotada e o modo de operação da microrrede.

6 CONCLUSÃO E TRABALHOS FUTUROS

6.1 Conclusões

Este trabalho propôs a modelagem e desenvolvimento em Python de despacho econômico ótimo de uma microrrede com múltiplos recursos energéticos, a saber: geração despachável, geração renovável, cargas controláveis e sistema de armazenamento em cenários de operação ilhada e conectada à rede externa, incluindo o fluxo bidirecional.

Para a solução do despacho econômico ótimo foram adotados três métodos distribuídos que utilizam agentes: Consenso, Difusão e Difusão Exata. Os métodos foram comparados quanto a diferentes aspectos: resultados obtidos, velocidade de convergência, esforço computacional e privacidade de informação. Além disso, para o método da Difusão Exata, comparou-se o desempenho de diferentes tipos de matrizes de peso, duplamente estocásticas e estocásticas à esquerda.

Os métodos distribuídos foram analisados em cinco cenários, três referentes ao modo de operação ilhado e dois ao modo conectado. No modo ilhado, verificou-se a efetividade da modelagem do agente bateria, analisando-se o seu carregamento e descarregamento. Além disso, verificou-se um cenário de necessidade de corte de carga, priorizando-se o corte de cargas não-críticas. Nesses cenários, os agentes alcançaram a performance desejada para as quais foram modelados e os resultados foram compatíveis entre os diferentes métodos. Para este modo, a Difusão se destacou com menor velocidade de convergência e esforço computacional. A Difusão Exata através da Matriz *Averaging Rule* obteve o melhor desempenho dentre as matrizes analisadas seguida pela matriz *Hasting Rules*, cujos desempenhos foram similares aos obtidos através da Difusão. O Consenso, por sua vez, obteve resultados bastante inferiores aos demais métodos.

No modo conectado, caracterizado por um agente (rede) compartilhando constantemente o valor da tarifa para a qual os outros agentes devem convergir percebeu-se uma velocidade de convergência mais rápida para todos os métodos, não havendo grandes disparidades entre as quantidades de iterações necessárias como as verificadas no modo ilhado. Ainda assim, destacou-se a Difusão com poucas iterações necessárias até a convergência e cujos valores foram bastante próximos aos verificados no Consenso. De forma geral, verificou-se que nesse modo, a Difusão Exata convergiu com mais iterações, sendo os melhores desempenhos obtidos através das matrizes *Hasting Rules* e *Averaging Rule*. Ainda abordando a Difusão Exata, destaca-se que

a utilização da matriz *Averaging Rule*, além de conferir uma convergência com menos iterações se comparado a outras matrizes passíveis de utilização com a Difusão Exata, garante maior privacidade aos agentes.

Além da análise de esforço computacional e velocidade de convergência, abordou-se estratégias verificadas na literatura que contribuem para efficientizar o despacho de uma MR como a adoção de um ganho de *feedback* variável por agente e por método, além da indicação da inicialização de variáveis como o custo incremental e variáveis intermediárias.

Assim, conclui-se que a adoção de estratégias distribuídas mostra-se eficaz na obtenção do despacho econômico ótimo, sendo bastante compatível com os novos modelos de redes elétricas. Os diferentes métodos distribuídos analisados neste trabalho apresentaram vantagens em diferentes cenários e apresentaram bons resultados.

6.2 Trabalhos Futuros

Visando melhorias no presente trabalho, são sugeridos as seguintes considerações para trabalhos futuros:

- Aplicação dos métodos e cenários descritos em uma plataforma multiagente com protocolos de comunicação padrão FIPA;
- Ampliação do problema para cenários com transações de energia entre múltiplas microrredes;
- Adoção de outras estratégias de modelagem do agente carga através de resposta a demanda;
- Análise do problema considerando perdas em linhas e custos de manutenção das fontes renováveis.

REFERÊNCIAS

- ABSOLAR. **Energia solar fotovoltaica no Brasil infográfico ABSOLAR**. 2022. Disponível em: <https://www.absolar.org.br/mercado/infografico/>. Acesso em: 08 set. 2022.
- ACKERMANN, T.; ANDERSSON, G.; SÖDER, L. Distributed generation: a definition. **Electric Power Systems Research**, [S. l.], v. 57, n. 3, p. 195–204, 2001.
- AGUIAR, A. S. de. **Equivalente certo e medidas de risco em decisões de comercialização de energia elétrica**. 2008. Tese (Doutorado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.
- ALI, H.; HUSSAIN, A.; BUI, V.-H.; KIM, H.-M. Consensus algorithm-based distributed operation of microgrids during grid-connected and islanded modes. **IEEE Access**, IEEE, [S. l.], v. 8, p. 78151–78165, 2020.
- ALMEIDA, R. G. **Gerenciamento e controle distribuído hierárquico primário e secundário aplicado a microrrede ca**. 2017. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2019.
- AZEVEDO, G. M. S. **Controle e operação de conversores em microrredes**. 2017. 164 f. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Pernambuco, Recife, 2011.
- AZEVEDO, R. de; CINTUGLU, M. H.; MA, T.; MOHAMMED, O. A. Multiagent-based optimal microgrid control using fully distributed diffusion strategy. **IEEE Transactions on Smart Grid**, IEEE, [S. l.], v. 8, n. 4, p. 1997–2008, 2017.
- BAKIRTZIS, A.; PETRIDIS, V.; KAZARLIS, S. Genetic algorithm solution to the economic dispatch problem. **IEE proceedings-generation, transmission and distribution**, IET, [S. l.], v. 141, n. 4, p. 377–382, 1994.
- CHEN, C.-L.; CHEN, N. Direct search method for solving economic dispatch problem considering transmission capacity constraints. **IEEE transactions on power systems**, IEEE, [S. l.], v. 16, n. 4, p. 764–769, 2001.
- CHENG, S.-L.; HWANG, C. Optimal approximation of linear systems by a differential evolution algorithm. **IEEE Transactions on Systems, man, and cybernetics-part a: systems and humans**, IEEE, [S. l.], v. 31, n. 6, p. 698–707, 2001.
- CHIANG, C.-L. Improved genetic algorithm for power economic dispatch of units with valve-point effects and multiple fuels. **IEEE transactions on power systems**, IEEE, [S. l.], v. 20, n. 4, p. 1690–1699, 2005.
- COSTA, P. T.; SILVA, L. S. **Métodos numéricos para zeros de funções**. 2009. Monografia (Curso de Especialização em Matemática) – Departamento de Matemática, Universidade Federal de Santa Catarina, Florianópolis, 2009.
- EPE, E. de P. E. **Recursos energéticos distribuídos: impactos no planejamento energético: Nota de discussão**. [S. l.], 2018. Disponível em: <https://www.epe.gov.br/sites-pt/sala-de-imprensa/noticias/Documents/ND%20-%20Recursos%20Energ%C3%A9ticos%20Distribu%C3%ADdos.pdf>. Acesso em: 08 set. 2022.

EPE, E. de P. E. **Balço energético nacional 2021**: Ben. [S. l.], 2021. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2021>. Acesso em: 08 set. 2022.

EYER, J. M.; COREY, G. P. **Energy storage for the electricity grid: benefits and market potential assessment guide: a study for the doe energy storage systems program**. Sandia National Laboratories (SNL) Albuquerque, NM, and Livermore, California, 2010.

FARHANGI, H. The path of the smart grid. **IEEE Power Energy Magazine**, [S. l.], v. 8, p. 18–28, 2010.

FIRESTONE, R.; MARNAY, C. Energy manager design for microgrids. **Lawrence Berkeley National Laboratory**, [S. l.], 2005. Disponível em: <https://api.semanticscholar.org/CorpusID:167037148>. Acesso em: 08 set. 2022.

FUENTES-BRACAMONTES, R. Is unbundling electricity services the way forward for the power sector? **The Electricity Journal**, [S. l.], v. 29, n. 9, p. 16–20, 2016.

GALIANA, F. D.; CONEJO, A. J. **5 Economics of Electricity Generation**. [S. l.]: Taylor Francis Group, 2009.

HATZIARGYRIOU, N. **Microgrids: Architectures and Control**. [S. l.]: Wiley-IEEE Press, 2014.

HE, Y.; WANG, W.; WU, X. Multi-agent based fully distributed economic dispatch in microgrid using exact diffusion strategy. **IEEE Access**, IEEE, [S. l.], v. 8, p. 7020–7031, 2019.

HUANG, J.; GUPTA, V.; HUANG, Y.-F. Electric grid state estimators for distribution systems with microgrids. *In*: 46TH ANNUAL CONFERENCE ON INFORMATION SCIENCES AND SYSTEMS(CISS), 2012. "**Proceedings [...]**". Princeton, 2012. p. 1–6.

JIAN, L.; ZHAO, Y.; HU, J.; LI, P. Distributed inexact consensus-based admm method for multi-agent unconstrained optimization problem. **IEEE Access**, IEEE, [S. l.], v. 7, p. 79311–79319, 2019.

KHAITAN, S. K.; MCCALLEY, J. D.; LIU, C. C. **Cyber physical systems approach to smart electric power grid**. [S. l.]: Springer, 2015.

KUO, C.-C. A novel coding scheme for practical economic dispatch by modified particle swarm approach. **IEEE Transactions on Power Systems**, IEEE, [S. l.], v. 23, n. 4, p. 1825–1835, 2008.

LASSETER, R.; AKHIL, A.; MARNAY, C.; STEPHENS, J.; DAGLE, J.; GUTTROMSOM, R.; MELIOPOULOUS, A. S.; YINGER, R.; ETO, J. **Integration of distributed energy resources**. [S. l.], 2002.

LI, P.; XU, D.; ZHOU, Z.; LEE, W.-J.; ZHAO, B. Stochastic optimal operation of microgrid based on chaotic binary particle swarm optimization. **IEEE Transactions on Smart Grid**, IEEE, [S. l.], v. 7, n. 1, p. 66–73, 2015.

LIN, W.-M.; CHENG, F.-S.; TSAY, M.-T. Nonconvex economic dispatch by integrated artificial intelligence. **IEEE Transactions on Power systems**, IEEE, [S. l.], v. 16, n. 2, p. 307–311, 2001.

LOIA, V.; VACCARO, A. Decentralized economic dispatch in smart grids by self-organizing dynamic agents. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, IEEE, [S. l.], v. 44, n. 4, p. 397–408, 2013.

MA, W.-J.; WANG, J.; GUPTA, V.; CHEN, C. Distributed energy management for networked microgrids using online admm with regret. **IEEE Transactions on Smart Grid**, IEEE, [S. l.], v. 9, n. 2, p. 847–856, 2016.

MARNAY, C. E. A. Microgrid evolution roadmap. *In: 2015 INTERNATIONAL SYMPOSIUM ON SMART ELECTRIC DISTRIBUTION SYSTEMS AND TECHNOLOGIES*, 2015. "Proceedings [...]". Vienna, 2015. p. 139–144.

NIKMEHR, N.; RAVADANEGH, S. N. A study on optimal power sharing in interconnected microgrids under uncertainty. **International Transactions on Electrical Energy Systems**, Wiley Online Library, [S. l.], v. 26, n. 1, p. 208–232, 2016.

OLIVEIRA, G. A. D. **Microrredes em Mercados de Energia Elétrica**. 2017. 164 f. Tese (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2017.

PARISIO, A.; RIKOS, E.; GLIELMO, L. A model predictive control approach to microgrid operation optimization. **IEEE Transactions on Control Systems Technology**, IEEE, [S. l.], v. 22, n. 5, p. 1813–1827, 2014.

PETROLEUM, B. Bp statistical review of world energy. **BRITISH PETROLEUM**, S1, p. 16–20, 2022.

RAHBARI-ASR, N.; CHOW, M.-Y. Cooperative distributed demand management for community charging of phev/pevs based on kkt conditions and consensus networks. **IEEE Transactions on Industrial Informatics**, IEEE, [S. l.], v. 10, n. 3, p. 1907–1916, 2014.

RAYA-ARMENTA, J. M.; BAZMOHAMMADI, N.; AVINA-CERVANTES, J. G.; SAEZ, D.; VASQUEZ, J. C.; GUERRERO, J. M. Energy management system optimization in islanded microgrids: An overview and future trends. **Renewable and Sustainable Energy Reviews**, Elsevier, [S. l.], v. 149, p. 111327, 2021.

SAYED, A. H. Diffusion adaptation over networks. *In: ACADEMIC PRESS LIBRARY IN SIGNAL PROCESSING*. [S. l.]: Elsevier, 2014. v. 3, p. 323–453.

SAYED, A. H. *et al.* Adaptation, learning, and optimization over networks. **Foundations and Trends® in Machine Learning**, Now Publishers, Inc., [S. l.], v. 7, n. 4-5, p. 311–801, 2014.

SHADMAND, M. B.; BALOG, R. S. Multi-objective optimization and design of photovoltaic-wind hybrid system for community smart dc microgrid. **IEEE Transactions on Smart Grid**, IEEE, [S. l.], v. 5, n. 5, p. 2635–2643, 2014.

SIOHANSI, F. P. . smart grid: Integrating renewable, distributed and efficient energy. **Waltham, MA: Elsevier**, 2012.

TANG, Z.; HILL, D. J.; LIU, T. A novel consensus-based economic dispatch for microgrids. **IEEE Transactions on Smart Grid**, IEEE, [S. l.], v. 9, n. 4, p. 3920–3922, 2018.

WANG, R.; LI, Q.; ZHANG, B.; WANG, L. Distributed consensus based algorithm for economic dispatch in a microgrid. **IEEE Transactions on Smart Grid**, IEEE, [S. l.], v. 10, n. 4, p. 3630–3640, 2018.

WANG, X.; LINGBO, L.; LUJANO-ROJAS, J. M.; ARTAL-SEVIL, J. S.; YUSTA, J. M.; DOMÍNGUEZ-NAVARRO, J. A. Economic dispatch of microgrid based on multi-agent system. *In: FOURTEENTH INTERNATIONAL CONFERENCE ON ECOLOGICAL VEHICLES AND RENEWABLE ENERGIES (EVER)*, 2019. "**Proceedings [...]**". Monte-Carlo, 2019. p. 1–6.

XU, Y.; ZHANG, W.; LIU, W.; WANG, X.; FERRESE, F.; ZANG, C.; YU, H. Distributed subgradient-based coordination of multiple renewable generators in a microgrid. **IEEE Transactions on Power Systems**, IEEE, [S. l.], v. 29, n. 1, p. 23–33, 2013.

YANG, S.; TAN, S.; XU, J.-X. Consensus based approach for economic dispatch problem in a smart grid. **IEEE Transactions on Power Systems**, IEEE, [S. l.], v. 28, n. 4, p. 4416–4426, 2013.

YU, M.; SONG, C.; FENG, S.; TAN, W. A consensus approach for economic dispatch problem in a microgrid with random delay effects. **International Journal of Electrical Power & Energy Systems**, Elsevier, [S. l.], v. 118, p. 105794, 2020.

YUAN, K.; YING, B.; ZHAO, X.; SAYED, A. H. Exact diffusion for distributed optimization and learning—part i: Algorithm development. **IEEE Transactions on Signal Processing**, IEEE, [S. l.], v. 67, n. 3, p. 708–723, 2018.

ZHANG, W.; MA, Y.; LIU, W.; RANADE, S. J.; LUO, Y. Distributed optimal active power dispatch under constraints for smart grids. **IEEE Transactions on Industrial Electronics**, IEEE, [S. l.], v. 64, n. 6, p. 5084–5094, 2016.

Código-fonte 1 – Despacho Econômico Modo Ilhado

```
1  '''
2  Dados do Problema:
3
4      Agente 01: Carga nao critica
5      Agente 02: Carga critica
6      Agente 03: Renovaveis
7      Agente 04: Geracao Classica
8  '''
9
10 ##### Importando Bibliotecas#####
11
12 import numpy as np
13 import matplotlib.pyplot as plt
14 import time
15
16 ##### Modelagem dos Agentes #####
17 #Identificacao
18 Carga=[0,1]
19 Ren=[2]
20 Desp=[3]
21 Bat=[4]
22
23 #Agente Bateria
24 pmaxess = 40
25 alp_ess = 2
26 beta = 8
27 '''
28 #Carga Baixa:
29 soc=0.2
30 '''
31 '''
```

```
32 #Carga Media:
33 soc = 0.4
34 '''
35
36
37 #Carga Alta:
38 soc=0.1
39
40 bet_ess = alp_ess*pmaxess*(1-soc) + beta
41
42 #Agente Geracao Renovavel
43
44 '''
45 #Carga Baixa
46 P_ren=np.array([0,0,10,0,0])
47 '''
48 '''
49 #Carga Media
50 P_ren=np.array([0,0,8.5,0,0])
51 '''
52
53 #Carga Alta:
54 P_ren=np.array([0,0,13.15,0,0])
55
56
57 #Agente Carga
58 #Limites de Carga:
59 '''
60 #Carga Baixa:
61 Carga_lim=[18.6,30]
62 '''
63
```

```
64 '''
65 #Carga Media:
66 Carga_lim=[31.34,32.15]
67 '''
68
69
70 #Carga Alta:
71 Carga_lim=[30,42.9]
72
73 #Parametros da Funcao Utilidade :
74
75 '''
76 #Baixa e Media
77 w=[-36.33,-44.46,0,0,0 ]
78 u=[w[0]/Carga_lim[0],w[1]/Carga_lim[1],0,0,0]
79 '''
80
81
82 #Alta:
83 w=[-200.25059791, -900.44001645]
84 u=[w[0]/30,w[1]/44.9,0,0,0]
85
86 #Parametros de Custo
87 alp = np.array([0,0,0,0.18,2])
88 bet = np.array([1,1,1,97,bet_ess])
89
90 #Numero de agentes despachaveis:
91 nDG=2
92
93 #Numero de Agentes:
94 nG = len(alp)
95
```



```

96 ##Inicializacao dos Parametros do Consenso #####
97 #Epsilon:
98
99 #Epsilon:
100 epil = np.array([0.09151453, 0.09793093, 0.08217902,
101                 0.08346563, 0.09840744])
102
102 #Matriz de Adjacencias:
103 A = np.array([[0,1,0,0,1],
104              [1,0,1,0,0],
105              [0,1,0,1,0],
106              [0,0,1,0,1],
107              [1,0,0,1,0]])
108
109 #Matriz de Grau:
110 D=np.diag(np.sum(A, axis=1))
111
112 #Matriz Laplaciana:
113 L = D - A
114
115 #Matriz Identidade:
116 I=np.identity(len(A))
117
118 #Matriz Mean Metropolis:
119 MM=np.zeros([nG,nG])
120 for i in range (0,nG):
121     for j in range(0,nG):
122         if(i!=j):
123             MM[i,j] = 2./(D[i,i] + D[j,j] + 1)
124 MM=np.multiply(A,MM)
125 for i in range(0,nG):
126     MM[i,i] = 1 - sum(MM[i,:])

```

```
127
128 #Numero Maximo de Iteracoes:
129 N_max=15000
130 N_max+=1
131
132 #Parametro de Parada:
133 diff=10                # Diferenca inicial
134 diff_min=0.0001       # Diferenca minima de
                        convergencia
135
136
137 n_algorit=0
138 flag=np.zeros(nG)
139
140 Plim_inf = np.array([0,0,0,-50,-(soc*pmaxess)])
141 Plim_sup = np.array([0,0,0,0,(1-soc)*pmaxess])
142
143 #Agentes que ultrapassaram a Potencia Maxima:
144 P_u_max=[]
145
146 #Agentes que ultrapassaram a Potencia Minima:
147 P_u_min=[]
148
149 #Agentes que nao ultrapassaram os limites de potencia :
150 P_n=[]
151
152
153 ##### Algoritmo de Consenso #####
154 tempo1=time.time()
155 while(sum(flag)!=0 or n_algorit==0):
156     #Inicializando as Potencias dos Agente:
157
```

```
158 #Numero Maximo de Iteracoes:
159 N_max=15000
160 N_max+=1
161 Pg=np.zeros([N_max,nG])
162
163 #Custo Incremental:
164 r = np.zeros([N_max,nG])
165
166 #Inicializando o Custo Incremental dos Agente:
167
168 #Agente Renovavel:
169 for i in Ren:
170     r[0,i]=0
171
172 #Agente Carga:
173 for i in Carga:
174     r[0,i]=w[i]
175
176 #Agente Despachavel:
177 for i in Desp:
178     r[0,i]=bet[i]
179
180 #Agente Bateria:
181 for i in Bat:
182     r[0,i]=bet[i]
183
184 #Inicializando o Power Mismatch:
185 Pd=np.zeros([N_max,nG])
186 Pd[0]=sum(P_ren)/nG
187
188 #Flag para rodar o while
189 flag=np.zeros(nG)
190
191 #Critério de Parada:
```

```

190     diff=10
191     i=0
192
193     #Consenso:
194
195     while(i!=N_max-1 and diff>diff_min):
196         d=np.zeros(nG)
197         for j in range(0,len(MM)):
198             r[i+1,j] = MM[j,:]*r[i,:] + epil[j]*Pd[i,j]
199
200             if j in Ren:
201                 Pg[i+1,j]=0
202             if j in Carga:
203                 if(abs(Pg[i,j])>=abs(w[j]/u[j])):
204                     Pg[i+1,j]=w[j]/u[j]
205                 else:
206                     Pg[i+1,j] = -(r[i+1,j]-w[j])/(u[j])
207             if j in Bat:
208                 if j in P_n or n_algorit==0:
209                     Pg[i+1,j] = (r[i+1,j] - bet[j])/(2*alp[
210                         j])
211                 elif j in P_u_max:
212                     Pg[i+1,j]=Plim_sup[j]
213                 elif j in P_u_min:
214                     Pg[i+1,j]=Plim_inf[j]
215             if j in Desp:
216                 if j in P_n or n_algorit==0:
217                     Pg[i+1,j] = (r[i+1,j] - bet[j])/(2*alp[
218                         j])
219                 elif j in P_u_max:
220                     Pg[i+1,j]=Plim_sup[j]
221                 elif j in P_u_min:

```

```

220         Pg[i+1,j]=Plim_inf[j]
221
222         Pd[i+1,j]=Pd[i,:]*MM[j,:] - (Pg[i+1,j] - Pg[i,j]
223         ])
224
225         d=abs(r[i+1]-r[i])
226         if(i==0):
227             diff=1
228         else:
229             diff=max(d)
230         i+=1
231 #Corte do i:
232 r=r[:i,:]
233 Pg=Pg[:i,:]
234 print("algoritmo:",n_algorit)
235 if n_algorit==0:
236     salve_Pg=Pg
237     salve_r=r
238     salve_Pd=Pd
239 inter=i
240 print("inter:",inter)
241 print("Pg:",Pg[-1])
242 #Limites de Potencia
243 for i in range(0,nG):
244     if(Pg[-1,i]>=Plim_sup[i]):
245         if i in Desp:
246             if n_algorit==0:
247                 P_u_max.append(i)
248                 flag[j]=1
249             else:
250                 if i in P_n:
251                     P_n.remove(i)

```

```
251         P_u_max.append(i)
252         flag[i]=1
253     elif i in P_u_min:
254         P_u_min.remove(i)
255         P_u_max.append(i)
256         flag[i]=1
257     if i in Bat:
258         if n_algorit==0:
259             P_u_max.append(i)
260             flag[i]=1
261         else:
262             if i in P_n:
263                 P_n.remove(i)
264                 P_u_max.append(i)
265                 flag[i]=1
266             elif i in P_u_min:
267                 P_u_min.remove(i)
268                 P_u_max.append(i)
269                 flag[i]=1
270     elif(Pg[-1,i]<=Plim_inf[i]):
271         if i in Desp:
272             if n_algorit==0:
273                 P_u_min.append(i)
274                 flag[i]=1
275             else:
276                 if i in P_n:
277                     P_n.remove(i)
278                     P_u_min.append(i)
279                     flag[i]=1
280                 elif i in P_u_max:
281                     P_u_max.remove(i)
282                     P_u_min.append(i)
```

```
283             flag[i]=1
284         if i in Bat:
285             if n_algorit==0:
286                 P_u_min.append(i)
287                 flag[i]=1
288             else:
289                 if i in P_n:
290                     P_n.remove(i)
291                     P_u_min.append(i)
292                     flag[i]=1
293                 elif i in P_u_max:
294                     P_u_max.remove(i)
295                     P_u_min.append(i)
296                     flag[i]=1
297         else:
298             if i in P_n:
299                 pass
300             elif i in P_u_max:
301                 P_u_max.remove(i)
302                 P_n.append(i)
303             elif i in P_u_min:
304                 P_u_min.remove(i)
305                 P_n.append(i)
306             else:
307                 P_n.append(i)
308
309         P_sup=0
310         for a in P_u_max:
311             P_sup += Plim_sup[a]
312 #Verificacao balanco de potencia
313         P_inf=0
314         for a in P_u_min:
```

```

315         P_inf += Plim_sup[a]
316     if P_sup > sum(Carga_lim):
317         flag_sem_limites=0
318         flag_limite_superior =1
319         n_algorit+=1
320         print("flag:",flag)
321 tempo2=time.time()
322 print("\nTempo Consenso com restricao:",tempo2-tempo1)
323 print("\n Parou na interacao:",inter)
324 #Colocar isso dentro do algoritmo
325 r=r[:inter,:] #Vai cortar a matriz ate a parte util,se
        parar por diferenca
326 Pg=Pg[:inter,:]

```

Código-fonte 2 – Despacho Econômico Modo Conectado

```

1 ##### Definicao dos Agentes#####
2
3 '''
4 Dados do Problema:
5
6 Agente 00: Carga
7 Agente 01: Renovaveis
8 Agente 02: Geracao Classica
9 Agente 03: Bateria
10 Agente 04: PCC
11 '''
12
13 ##### Importando Bibliotecas #####
14
15 print("Iniciando codigo")
16

```



```
17 import numpy as np
18 import matplotlib.pyplot as plt
19 import time
20
21 ##### Modelando os cinco agentes #####
22 #Identificacao
23 Carga=[0]
24 Ren=[1]
25 Desp=[2]
26 Bat=[3]
27 Pcc=[4]
28
29 #Agente Bateria
30 pmaxess = 40
31 alp_ess = 0.3
32 beta = 114
33 soc=0.9
34 bet_ess = alp_ess*pmaxess*(1-soc) + beta
35
36 #Agente Carga
37 Dem=np.array([40,0,0,0,0])
38
39 #Agente Geracao Renovavel
40 P_ren=np.array([0,10,0,0,0])
41
42 #Demanda liquida
43 P_carga=np.array([30,0,0,0,0])
44
45 #Parametros de Custo
46 alp = np.array([0,0,0.18,0.3,0])
47 bet = np.array([1,1,97,bet_ess,112.5])
48
```

```
49 #Numero de agentes despachaveis:
50 nDG=2
51
52 #Numero de Agentes:
53 nG = len(alp)
54
55
56 ##### Parametros do Consenso #####
57
58 epil = np.array([0.01, 0.01, 0.01, 0.01, 0.01])
59
60 #Matriz de Adjacencias:
61 A = np.array([[0,1,0,0,1],
62               [1,0,1,0,0],
63               [0,1,0,1,0],
64               [0,0,1,0,1],
65               [1,0,0,1,0]])
66
67 #Matriz de Grau:
68 D=np.diag(np.sum(A, axis=1))
69
70 #Matriz Laplaciana:
71 L = D - A
72
73 #Matriz Identidade:
74 I=np.identity(len(A))
75
76 #Matriz Mean Metropolis:
77 MM=np.zeros([nG,nG])
78 for i in range (0,nG):
79     for j in range(0,nG):
80         if(i!=j):
```

```

81             MM[i,j] = 2./(D[i,i] + D[j,j] + 1)
82 MM=np.multiply(A,MM)
83 for i in range(0,nG):
84     MM[i,i] = 1 - sum(MM[i,:])
85
86 #Numero Maximo de Iteracoes:
87 N_max=15000
88 N_max+=1
89
90 #Parametro de Parada:
91 diff=10                # Diferenca inicial
92 diff_min=0.0001       # Diferenca minima de
    convergencia
93
94
95 n_algorit=0
96 flag=np.zeros(nG)
97
98 Plim_sup = np.array([0,0,50,(soc*pmaxess),0])
99 Plim_inf = np.array([0,0,0,-(1-soc)*pmaxess,0])
100 #Agentes que ultrapassaram a Potencia Maxima:
101 P_u_max=[]
102
103 #Agentes que ultrapassaram a Potencia Minima:
104 P_u_min=[]
105
106 #Agentes que nao ultrapassaram os limites de potencia :
107 P_n=[]
108
109 ##### Algoritmo de Consenso#####
110 tempo1=time.time()
111 while(sum(flag)!=0 or n_algorit==0):

```

```
112 #Iniciando as Potencias dos Agente:
113
114 #Numero Maximo de Iteracoes:
115 N_max=15000
116 N_max+=1
117 Pg=np.zeros([N_max,nG])
118
119 #Custo Incremental:
120 r = np.zeros([N_max,nG])
121
122 #Iniciando o Custo Incremental dos Agente:
123
124 #Agente PCC
125 for i in Pcc:
126     r[0,i]=bet[i]
127
128 #Agente Renovavel:
129 for i in Ren:
130     r[0,i]=0
131
132 #Agente Carga:
133 for i in Carga:
134     r[0,i]=0
135
136 #Agente Despachavel:
137 for i in Desp:
138     r[0,i]=bet[i]
139
140 #Agente Bateria:
141 for i in Bat:
142     r[0,i]=bet[i]
143
```

```

144 #Inicializando o Power Mismatch:
145 Pd=np.zeros([N_max,nG])
146 Pd[0]=sum(P_carga)/nG
147
148 #Flag para rodar o while
149 flag=np.zeros(nG)
150 #Crit rio de Parada:
151 diff=10
152 i=0
153 while(i!=N_max-1 and diff>diff_min):
154     d=np.zeros(nG)
155     for j in range(0,len(MM)):
156         if (j!=4):
157             r[i+1,j] = MM[j,:]*r[i,:] + epil[j]*Pd[i,j]
158         if (j==4):
159             r[i+1,j] = 112.5
160         if j in Ren:
161             Pg[i+1,j]=0
162         if j in Carga:
163             Pg[i+1,j]=0
164         if j in Bat:
165             if j in P_n or n_algorit==0:
166                 Pg[i+1,j] = (r[i+1,j] - bet[j])/(2*alp[
167                     j])
168             elif j in P_u_max:
169                 Pg[i+1,j]=Plim_sup[j]
170             elif j in P_u_min:
171                 Pg[i+1,j]=Plim_inf[j]
172         if j in Desp:
173             if j in P_n or n_algorit==0:
174                 Pg[i+1,j] = (r[i+1,j] - bet[j])/(2*alp[
175                     j])

```

```

174         elif j in P_u_max:
175             Pg[i+1,j]=Plim_sup[j]
176         elif j in P_u_min:
177             Pg[i+1,j]=Plim_inf[j]
178         if j in Pcc:
179             Pg[i+1,j] = sum(P_carga) - ((Pg[i+1,2] + Pg[i
180                 +1,3]))
181             Pd[i+1,j]=Pd[i,:]*MM[j,:] - (Pg[i+1,j] - Pg[i,j
182                 ])
183             d=abs(r[i+1]-r[i])
184             if(i==0):
185                 diff=1
186             else:
187                 diff=max(d)
188             i+=1
189 #Corte do i:
190         r=r[:i,:]
191         Pg=Pg[:i,:]
192         inter=i
193         print("Pg:",Pg[-1])
194         #Limites de Potencia
195         for i in range(0,nG):
196             if(Pg[-1,i]>=Plim_sup[i]):
197                 if i in Desp:
198                     if n_algorit==0:
199                         P_u_max.append(i)
200                         flag[j]=1
201                     else:
202                         if i in P_n:
203                             P_n.remove(i)
204                             P_u_max.append(i)

```

```
204         flag[i]=1
205     elif i in P_u_min:
206         P_u_min.remove(i)
207         P_u_max.append(i)
208         flag[i]=1
209     if i in Bat:
210         if n_algorit==0:
211             P_u_max.append(i)
212             flag[i]=1
213         else:
214             if i in P_n:
215                 P_n.remove(i)
216                 P_u_max.append(i)
217                 flag[i]=1
218             elif i in P_u_min:
219                 P_u_min.remove(i)
220                 P_u_max.append(i)
221                 flag[i]=1
222     elif(Pg[-1,i]<=Plim_inf[i]):
223         if i in Desp:
224             if n_algorit==0:
225                 P_u_min.append(i)
226                 flag[i]=1
227             else:
228                 if i in P_n:
229                     P_n.remove(i)
230                     P_u_min.append(i)
231                     flag[i]=1
232                 elif i in P_u_max:
233                     P_u_max.remove(i)
234                     P_u_min.append(i)
235                     flag[i]=1
```

```
236         if i in Bat:
237             if n_algorit==0:
238                 P_u_min.append(i)
239                 flag[i]=1
240             else:
241                 if i in P_n:
242                     P_n.remove(i)
243                     P_u_min.append(i)
244                     flag[i]=1
245                 elif i in P_u_max:
246                     P_u_max.remove(i)
247                     P_u_min.append(i)
248                     flag[i]=1
249         else:
250             if i in P_n:
251                 pass #
252             elif i in P_u_max:
253                 P_u_max.remove(i)
254                 P_n.append(i)
255             elif i in P_u_min:
256                 P_u_min.remove(i)
257                 P_n.append(i)
258             else:
259                 P_n.append(i)
260 # Soma das potencias dos agentes despachaveis (verificar
    equilibrio de potencia)
261     P_sup=0
262     for a in P_u_max:
263         P_sup += Plim_sup[a]
264     P_inf=0
265     for a in P_u_min:
266         P_inf += Plim_sup[a]
```



```
267     if P_sup > sum(Carga):
268         flag_sem_limites=0
269         flag_limite_superior =1
270         n_algorit+=1
271         print("flag:",flag)
272 tempo2=time.time()
273 print("\nTempo Consenso com restricao:",tempo2-tempo1)
274 print("\n Parou na interacao:",inter)
275
276 r=r[:inter,:] #Vai cortar a matriz at a parte util,se
        parar por diferenca
277 Pg=Pg[:inter,:]
```